



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA – CT

CENTRO DE CIÊNCIAS EXATAS E DA TERRA – CCET

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E ENGENHARIA DE PETRÓLEO -
PPGCEP



TESE DE DOUTORADO

USO DE GRÁFICOS DE CONTROLE PARA O MONITORAMENTO CONTÍNUO DA
RAZÃO ÁGUA-ÓLEO EM CAMPOS DA BACIA POTIGUAR

CARLA SIMONE DE LIMA TEIXEIRA ASSUNÇÃO

Natal/RN

2018

CARLA SIMONE DE LIMA TEIXEIRA ASSUNÇÃO

USO DE GRÁFICOS DE CONTROLE PARA O MONITORAMENTO CONTÍNUO DA
RAZÃO ÁGUA-ÓLEO EM CAMPOS DA BACIA POTIGUAR

Tese apresentada ao Programa de Pós-Graduação de
Ciência e Engenharia de Petróleo da Universidade
Federal do Rio Grande do Norte, como parte dos
requisitos para obtenção do grau de Doutora em
Ciência e Engenharia de Petróleo.

Orientadora: Profa. Dra. Marcela Marques Vieira

Co-orientadora: Profa. Dra. Linda Lee Ho

Natal/RN

2018

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Assunção, Carla Simone de Lima Teixeira.

Uso de gráficos de controle para o monitoramento contínuo da razão água-óleo em campos da Bacia Potiguar / Carla Simone de Lima Teixeira Assunção. - 2018.

111f.: il.

Tese (Doutorado)-Universidade Federal do Rio Grande do Norte, Centro de Ciências Exatas e da Terra, Pós Graduação em Ciência e Engenharia de Petróleo, Natal, 2018.

Orientadora: Dra. Marcela Marques Vieira.

Coorientadora: Dra. Linda Lee Ho.

1. Razão água-óleo - Tese. 2. Água Produzida - Tese. 3. Gráficos de Controle - Tese. 4. ARIMA - Tese. I. Vieira, Marcela Marques. II. Lee, Linda. III. Título.

RN/UF/BCZM

CDU 665.6/.7

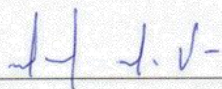
CARLA SIMONE DE LIMA TEIXEIRA ASSUNÇÃO

USO DE GRÁFICOS DE CONTROLE PARA O MONITORAMENTO CONTÍNUO DA
RAZÃO ÁGUA-ÓLEO EM CAMPOS DA BACIA POTIGUAR

Tese apresentada ao Programa de Pós-Graduação
de Ciência e Engenharia de Petróleo da
Universidade Federal do Rio Grande do Norte,
como parte dos requisitos para obtenção do grau
de Doutora em Ciência e Engenharia de Petróleo.

Aprovado em 21 / 08 / 2018

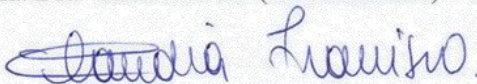
BANCA EXAMINADORA



Prof. Dra. Marcela Marques Vieira (Orientadora) - UFRN



Prof. Dra. Linda Lee Ho (Coorientadora) - USP



Prof. Dra. Claudia Aparecida Cavaleiro Francisco - UFRN



Prof. Dra. Luciana de Sousa Frazão - UFRN



Prof. Dra. Danyelle Medeiros de Araújo - IFRN

Natal/RN
2018

À minha filha: foi por você e para você, mesmo
antes de saber que você viria.

Às mulheres que enfrentam o mundo com os
filhos nos braços.

AGRADECIMENTOS

É impossível caminhar sozinha, se cheguei até aqui é porque tive pessoas me apoiando e incentivando. O maior deles foi meu esposo Leonel, que durante todo o processo foi o meu maior incentivador. Sem seu apoio, tenho dúvidas se teria conseguido chegar até aqui.

Gostaria de agradecer também aos meus pais e irmã, por todo apoio e, principalmente, amor incondicional essencial para me fazer crescer a cada dia.

Quero também deixar um agradecimento especial à Professora Doutora Marcela, que sempre foi muito generosa e humana na orientação, conduzindo os “bastidores” do trabalho de maneira brilhante. Assim como a Professora Doutora Linda, que tem se tornado uma mentora e salvação na minha vida acadêmica. Ela me dá a sensação de que não estou sozinha e que eu posso ir além. Agradeço também às duas por todos os conselhos e conversas que foram muito além do trabalho e me prepararam para a vida.

Muito obrigada ainda à Doutora Danyelle Medeiros pela contribuição dada na banca de qualificação e por sempre estar prontamente disponível a ajudar.

Agradeço aos meus companheiros, em especial ao Professor Doutor Marcus Assunção, que ingressou junto comigo nessa jornada e nossos trabalhos, ainda que individuais, acabaram ganhando torcida mútua. O apoio de alguém com empatia é essencial nessa fase. Obrigada também aos amigos do IFRN, Campus São Gonçalo do Amarante, que sempre mostraram muito apoio e torcida durante todo o período do doutorado;

Deixo aqui ainda a minha homenagem ao meu eterno aluno David Allyson (em memória) pela ajuda fundamental na etapa de programação. Esta tese também carrega um pedacinho dele.

Ao PPGCEP e UFRN, obrigada pela oportunidade de capacitação e novos conhecimentos e à Empresa Petrobrás pela disponibilização dos dados utilizados na pesquisa.

“Que nada nos limite, que nada nos defina, que nada nos sujeite. Que a liberdade seja nossa própria substância, já que viver é ser livre. Porque alguém disse, e eu concordo, que o tempo cura, que a mágoa passa, que decepção não mata. E que a vida sempre, sempre continua.”

(Simone de Beauvoir)

RESUMO

Atualmente, o petróleo é a fonte de energia mais utilizada no mundo, porém, o maior resíduo decorrente da produção é a chamada água produzida (AP). Esta água não possui valor comercial e necessita de tratamento para ser destinada ou para descarte ou para reinjeção, durante os métodos de recuperação. Desta forma, a gestão da água produzida se torna onerosa e, por isso, necessita de ferramentas que a apoiem. Além disso, a proporção dos níveis de produção de água em relação aos níveis de produção de óleo é uma variável que subsidia a análise da viabilidade econômica do campo. Neste sentido, o presente trabalho propõe uma metodologia para monitoramento contínuo da razão água-óleo baseado em gráficos de controle. Ocorre que os dados de razão água-óleo são autocorrelacionados, o que gera a necessidade do ajuste de um modelo que minimize esta correlação para a aplicação destes gráficos. Desta forma, os dados foram ajustados segundo modelos ARIMA e os gráficos de controle foram elaborados com base nos resíduos resultantes. Os gráficos de controle estudados foram o gráfico de Shewhart e o CUSUM. Após esta aplicação, foi realizada uma simulação a fim de avaliar o desempenho de cada um dos gráficos para determinar o melhor método de monitoração.

Palavras-chave: Razão água-óleo. Água produzida. Gráficos de controle. ARIMA.

ABSTRACT

Currently, oil is the energy source most used in the world, however, the greatest application is produced by produced water (PA). This water doesn't have a commercial price and treatment is necessary for disposal or for reinjection, during the recovery methods. In this way, the water produced management is costly and, therefore, it needs tools that support it. In addition, the water production levels proportion in relation to oil production levels is a variable that supports the field economic viability analysis. So, the present work proposes a methodology for continuous monitoring of the water-oil ratio based on control charts. However, the water-oil ratio data are autocorrelated, which generates needs to fit a model that minimizes this correlation for the application of these charts. In this way, the data were adjusted according to ARIMA models and the control charts were elaborated based on the resulting residues. The control graphs studied were Shewhart's charts and CUSUM. After this application, a simulation was performed to evaluate the performance of each of the graphs to determine the best monitoring method.

Keywords: Water-oil ratio. Produced water. Control charts. ARIMA.

SUMÁRIO

1	INTRODUÇÃO E OBJETIVOS	12
1.1	Importância do Estudo da Água Produzida.....	12
1.2	Objetivos	17
1.3	Estrutura da Tese.....	18
2	REVISÃO DA LITERATURA	20
2.1	Origem e Composição da Água Produzida.....	20
2.2	Gestão da Água Produzida.....	21
2.3	Séries Temporais e Modelos Arima.....	24
2.4	Gráficos de Controle.....	29
3	ETAPAS PARA O PLANEJAMENTO DOS GRÁFICOS DE CONTROLE	35
3.1	Área de Abrangência do Estudo.....	35
3.2	Etapas do Modelo Proposto	37
3.2.1	Análise dos dados.....	38
3.2.2	Ajuste do Modelo ARIMA.....	40
3.2.3	Determinação dos Limites de Controle e Simulação	41
4	APLICAÇÃO DOS GRÁFICOS DE CONTROLE PARA A RAO DOS CAMPOS DA BACIA POTIGUAR.....	44
4.1	Análise dos Dados	44
4.2	Ajuste do Modelo Arima	48
4.3	Determinação dos Limites de Controle e Simulação	50
4.4	Avaliação do Desempenho dos Gráficos	56
5	CONCLUSÕES	58
	REFERÊNCIAS BIBLIOGRÁFICAS	61

LISTA DE FIGURAS

Figura 1 - Evolução mundial da produção de água	14
Figura 2 - Evolução da produção de água, óleo e gás no Brasil de 2000 a 2015	15
Figura 3 - Resumo esquemático da estrutura da tese.....	19
Figura 4 - Exemplo de Correlograma com Mudança Abrupta de Direção.....	27
Figura 5 - Exemplo de Correlograma com Decaimento Rápido dos Valores Significativos ...	27
Figura 6 - Exemplo de Correlograma com Decaimento Lento (Série não estacionária).....	27
Figura 7 - Exemplos de Padrões de Decaimento	28
Figura 8 - A Bacia Potiguar.....	36
Figura 9 - Resumo das etapas do modelo	38
Figura 10 - Exemplo do recorte temporal realizado	39
Figura 11 - Fluxograma da metodologia proposta	43
Figura 12 - Análise da razão do campo F no software R	45
Figura 13 - Análise da razão do campo A no software R.....	46
Figura 14 - Análise da Primeira Diferença dos Dados da Razão do Campo F no software R .	47
Figura 15 - Valores da Primeira Diferença dos Dados da Razão do Campo A no software R	47
Figura 16 - Gráfico Shewhart para o ponto D	51
Figura 17 - Gráfico CUSUM para o Campo D.....	52
Figura 18 - Gráfico Shewhart para o CAMPO R	52
Figura 19 - Gráfico CUSUM para o Campo R.....	53
Figura 20 - Campos com pontos fora dos limites de controle Shewhart.....	54
Figura 21 - Campos com pontos fora dos limites de controle CUSUM.....	55
Figura 22 - Monitoramento do Campo K	55

LISTA DE TABELAS

Tabela 1 - Evolução da produção de petróleo por região geográfica	12
Tabela 2 - Campos <i>onshore</i> (suas idades, em meses) selecionados para a realização da pesquisa	37
Tabela 3 - Campos em que foram realizados recortes temporais	40
Tabela 4 - Modelos ARIMA ajustados.....	49
Tabela 5 - Limites de Controle	53
Tabela 6 - Número de Observações até o sinal	57
Tabela 7 - Resumo dos Resultados Obtidos	59

LISTA DE SIGLAS E ABREVIATURAS

ACF	Análise de autocorrelação
ANP	Agência Nacional de Petróleo
CONAMA	Conselho Nacional de Meio Ambiente
CUSUM	Cumulative Sum Chart
NMA	Número de Amostras até o sinal
PACF	Análise de autocorrelação parcial
PW	<i>Produced water</i>
RAO	Razão água-óleo

1 INTRODUÇÃO E OBJETIVOS

Neste capítulo estarão dispostos os conceitos e problemas levantados que justificam o desenvolvimento desta pesquisa. Além disso, também serão apresentados os objetivos deste trabalho, bem como a estrutura da Tese.

1.1 Importância do Estudo da Água Produzida

Atualmente, o petróleo é a fonte de energia mais utilizada no mundo. Em 2015, as reservas provadas de petróleo, no mundo, atingiram a marca de 1,7 trilhões de barris, segundo a Agência Nacional de Petróleo (ANP, 2016). Apesar das reservas não sofrerem alterações bruscas nos últimos anos, a produção, em 2015, aumentou 3,2% em relação a 2014, devido à evolução dos métodos de recuperação, principalmente.

A Tabela 1 apresenta a evolução da produção de Petróleo por continente entre 2006 e 2015.

Tabela 1 - Evolução da produção de petróleo por região geográfica											
REGIÕES GEOGRÁFICAS E BLOCOS ECONÔMICOS	PRODUÇÃO DE PETRÓLEO (MIL BARRIS/DIA)										15/14
	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	%
TOTAL	82.487	82.277	82.818	81.182	83.283	84.097	86.218	86.591	88.834	91.670	3,19
América do Norte	13.726	13.631	13.159	13.447	13.843	14.310	15.535	16.934	18.786	18.676	-0,14
Américas Central e do Sul	7.463	7.295	7.376	7.322	7.348	7.401	7.322	7.344	7.605	7.712	1,39
Europa e Eurásia	17.587	17.800	17.577	17.760	17.699	17.390	17.124	17.166	17.206	17.463	1,49
Oriente Médio	25.764	25.322	26.372	24.723	25.827	28.160	28.532	28.181	28.557	30.098	5,40
África	10.011	10.269	10.246	9.890	10.142	8.548	9.327	8.711	8.371	8.375	0,06
Ásia-Pacífico	7.937	7.961	8.088	8.039	8.424	8.287	8.378	8.254	8.310	8.346	0,43

Fonte: ANP (2016)

Observa-se que, ainda que a produção mundial de óleo continue crescendo, este acréscimo tem ocorrido a taxas cada vez menores.

Durante o processo de produção de petróleo, existe um volume considerável de água a ser produzida conjuntamente. Esta água se encontra aprisionada nas rochas subterrâneas dos

reservatórios e chega à superfície juntamente com o óleo e gás, durante as atividades de produção.

A água conata (aquela cuja origem está associada à formação da própria rocha na qual ela se encontra) sempre está presente nos reservatórios, pois ela já saturava os poros das rochas quando o petróleo migrou até lá. Entretanto, é importante entender que a existência da água no reservatório não significa uma produção ou deslocamento imediato da mesma até o poço no início de sua vida produtiva. Para que a água se desloque e seja produzida é necessário que a sua saturação ultrapasse um valor mínimo.

Estas observações são válidas até o *breakthrough*, que é o momento em que a mobilidade da água supera a do óleo, aumentando a razão água-óleo (RAO). Nesta fase, a produção de água é contínua e cresce com o tempo.

Na prática, apesar de, no fundo do poço, óleo, água e gás se encontrarem separados, eles não são produzidos separadamente, pois, quando estes fluidos escoam através das tubulações no processo de produção, estes são submetidos à agitação e cisalhamento, tornando as fases emulsionadas. Deste modo, processos de separação são necessários (processamentos primários), bem como tratamentos específicos para que esta água seja reutilizada (para reinjeção) ou descartada.

É importante ressaltar que o petróleo é o fluido de maior interesse econômico no processo de produção e a água não possui valor comercial. Além disso, a água separada arrasta consigo uma grande quantidade de impurezas e poluentes (incluindo aditivos químicos, sal, óleo, compostos orgânicos e inorgânicos naturais e materiais radioativos naturais) e o processo de separação pode ser simples ou complexo, de acordo com as características dos fluidos, da localização do reservatório e dos interesses econômicos.

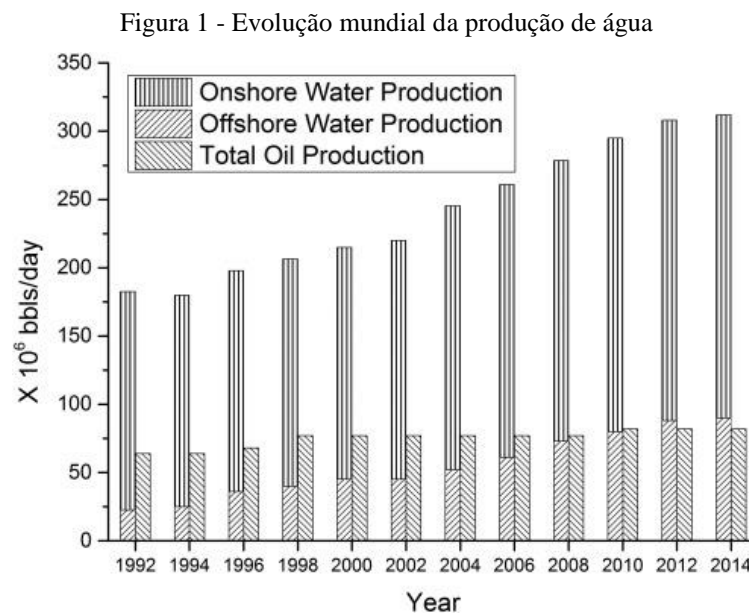
Cabe, ainda, salientar que a água produzida é o resíduo de maior volume na produção de petróleo e gás. Desta forma, os processos relacionados à gestão e tratamento desta água resultam em custos elevados, proporcionais aos níveis produzidos de água e à complexidade dos processos de tratamento.

Historicamente, diversos trabalhos se preocuparam em apresentar métodos de separação e tratamento da água, por meio de processos químicos ou físicos. Porém, ainda são escassos os estudos que usam monitoramento e gestão do volume desta água produzida, principalmente com enfoque nos custos provocados por este processo.

Em uma escala mundial, é possível observar que os volumes de água produzida também ultrapassam a produção dos componentes de maior valor agregado. Na produção no mar (*offshore*), essa diferença é ainda mais significativa, sendo apenas uma pequena parte desta

água reutilizada para reinjeção na produção, enquanto a maior parte da água é descartada após tratamento. Por exemplo, no ano de 2007, apenas 8,3% da água produzida no mar nos Estados Unidos foi reinjetada para melhorar a recuperação, enquanto 91,5% da água foi descartada no oceano (Clark; Veil, 2009). Deste modo, o aumento contínuo no volume deste resíduo no mundo resulta em uma maior preocupação com os efeitos da descarga dessa água no ambiente e o impacto deste fator na indústria petrolífera.


Na escala global, a proporção de água para óleo é de aproximadamente 3:1 para poços produtores de petróleo e é ainda maior para poços de gás (Neff et al., 2011), sendo superior em poços maduros que em novos. A Figura 1 apresenta a evolução na produção mundial de água e óleo entre os anos de 1992 e 2014.



Fonte: Fakhru'l-Razi et al., 2009; Netl, 2013, apud Zheng et al., 2016

No Brasil, há um declínio sistêmico na produção de óleo e, consequentemente, um aumento na produção de água, em reservatórios antigos, que ultrapassa o declínio natural esperado. A partir do ano de 2003, a produção de água no país ultrapassou a produção de óleo, como pode ser visto na Figura 2.

Figura 2 - Evolução da produção de água, óleo e gás no Brasil de 2000 a 2015



Fonte: Vieira (2017)

Segundo a Agência Nacional de Petróleo (ANP, 2014), no Brasil, somente as operações de produção em mar, no ano de 2013, registraram a geração de cerca de noventa e cinco milhões de metros cúbicos de água produzida, para uma produção de cento e sete milhões de m³ de petróleo, resultando em uma razão água-óleo igual a 0,89.

Já em 2013, na Bacia Potiguar, os volumes de água atingiram cerca de 1,13 milhões de metros cúbicos *versus* 0,43 milhões de metros cúbicos de óleo, resultando numa razão de 2,64. Ou seja, nesta bacia, tem-se produzido mais que o dobro de água que óleo.

Portanto, o gerenciamento do nível de água produzida passa a ser fator primordial para a sustentabilidade das operações e para dar subsídios para a tomada de decisões sobre a continuidade das operações. Desta forma, justifica-se a necessidade do uso de ferramentas que auxiliem na análise da viabilidade dos campos de exploração e produção com base neste componente.

A medida da Razão Água-Óleo (RAO) é a relação entre a vazão da água e a vazão do óleo, medidas em condições de superfície. Um valor elevado desta medida indica que o reservatório está produzindo mais água que óleo e a magnitude deste valor indica a desproporcionalidade entre os dois fluidos. Além disso, é esperado que, com o passar do tempo, essa razão sofra aumento contínuo.

Desta forma, o monitoramento contínuo desta razão fornece subsídios para a gestão da viabilidade dos reservatórios, bem como dá indícios sobre potenciais danos ambientais que possam vir a acontecer devido ao grande volume de água retirado. Assim, o uso de ferramentas para este monitoramento se mostra fundamental para a gestão dos campos de produção.

De maneira geral, o monitoramento de medidas de interesse auxilia a gestão na descoberta de desvios nos níveis de controle do processo que geram custos extras. Através de tais técnicas propõe-se o ajuste de limites que auxiliam a observação sobre o controle de medidas de interesse no processo. Os gráficos de controle estatístico se apresentam como uma importante ferramenta neste contexto, pois permitem o monitoramento contínuo dos valores, assim como a possibilidade de julgar se os desvios são ou não devidos à alguma causa especial e atuar corretivamente em situações de descontrole.

Esta ferramenta determina, estatisticamente, os limites de controle (superior e inferior) para avaliar a variabilidade natural de um processo. A partir do momento que uma medida de interesse ultrapassa um dos limites, assume-se que o processo não está sob controle estatístico (é dito que o processo está fora saiu do seu estado de controle). Tais gráficos foram inicialmente propostos para monitorar processos de manufatura, porém, recentemente vem sendo utilizados para monitorar outros tipos de processos (por exemplo, em saúde pública para julgar se determinada doença alcançou níveis epidêmicos, ver Woodall (2006) e Unkel et al. (2012)).

Porém, os gráficos de controle tradicionais consideram duas premissas básicas para sua utilização: os dados devem ser independentes e identicamente distribuídos. A aplicação de gráficos de controle para dados autocorrelacionados, onde uma observação é influenciada pela anterior em escala temporal, viola a primeira suposição de forma que o uso destes gráficos para esse tipo de dados acaba por gerar um excessivo número de alarmes falsos.

De modo geral, é observada, uma tendência de crescimento de forma contínua com o passar do tempo nas medidas das razões água-óleo. Este aspecto exige que os dados sejam modelados de forma a buscar remover os efeitos da autocorrelação para que os limites possam ser determinados.

A metodologia proposta nesse trabalho será aplicada a um conjunto de campos maduros da Bacia Potiguar como forma de ilustrar a sua eficiência. Desta forma, o uso de gráficos de controle no monitoramento da razão água-óleo tem como objetivo em julgar a continuidade ou não desses campos em termos desta variável.

Historicamente, vários autores propuseram técnicas específicas para o uso de gráficos de controle em dados autocorrelacionados. Woodall e Montgomery (1999) propuseram a realização de um ajuste em um modelo de séries temporais, por exemplo, um modelo ARIMA, e o monitoramento dos resíduos do modelo através de um gráfico de controle como os gráficos para medidas individuais, somas cumulativas (CUSUM) e o gráfico para médias móveis exponencialmente ponderadas (EWMA).

Além disso, Alwan e Roberts (1988) propuseram um gráfico de controle para os resíduos padronizados do modelo, utilizando esses resíduos em gráficos para variáveis tradicionais. O tema, gráficos de controle para dados auto correlacionados, continua sendo um tema de pesquisa, como por exemplo em Mastrangelo e Montgomery (1995); Atienza, Tang e Ang (1998); Jiang, Tisui e Woodall (2000); English et al. (2000); Pan e Jarrett (2004); Harris et al. (2016) e Vanhatalo e Kulahci (2016).

Desta forma, este trabalho justifica-se pela busca de propor metodologias para controle contínuo da razão água-óleo, em campos de produção da Bacia Potiguar, utilizando gráficos de controle para variáveis correlacionadas. Atualmente, a decisão pelo abandono dos poços de petróleo leva em conta fatores empíricos. Vale salientar que o abandono destes poços incorre em custos elevados, além de questões ambientais relevantes. Desta forma, o uso de ferramentas estatísticas é relevante do ponto de vista de auxiliar uma tomada de decisão com critérios numéricos e formais sobre a viabilidade destes postos.

Ademais, o uso de controle estatístico de processos na área de exploração e produção de petróleo é algo pouco explorado. Aliado a isso, soma-se o fato de o estudo ser realizado utilizando a razão entre duas variáveis, fato relativamente novo na literatura de controle estatístico de processos, sendo estas variáveis relevantes para a tomada de decisão da indústria em questão.

A pesquisa se concentrará em aplicar técnicas de monitoramento aos dados da RAO da Bacia Potiguar a fim de desenvolver uma metodologia de monitoração contínua para essa variável.

1.2 Objetivos

Neste cenário, este trabalho tem por objetivo principal **propor um método para monitoramento da Razão água-óleo de campos de produção de petróleo da Bacia Potiguar**, com emprego de Gráficos de Controles dos tipos Shewhart e Soma Acumulada (CUSUM), considerando os resíduos de um modelo ARIMA ajustado a cada campo. Para dar suporte à pesquisa, desenvolveram-se objetivos específicos:

- a) Propor um método para ajustar o modelo ARIMA para os dados coletados;
- b) Avaliar o controle estatístico de cada campo, por meio do monitoramento dos dados mais recentes;
- c) Comparar o gráfico Shewhart e o CUSUM a fim de determinar qual tem o melhor desempenho para o conjunto de dados estudado.

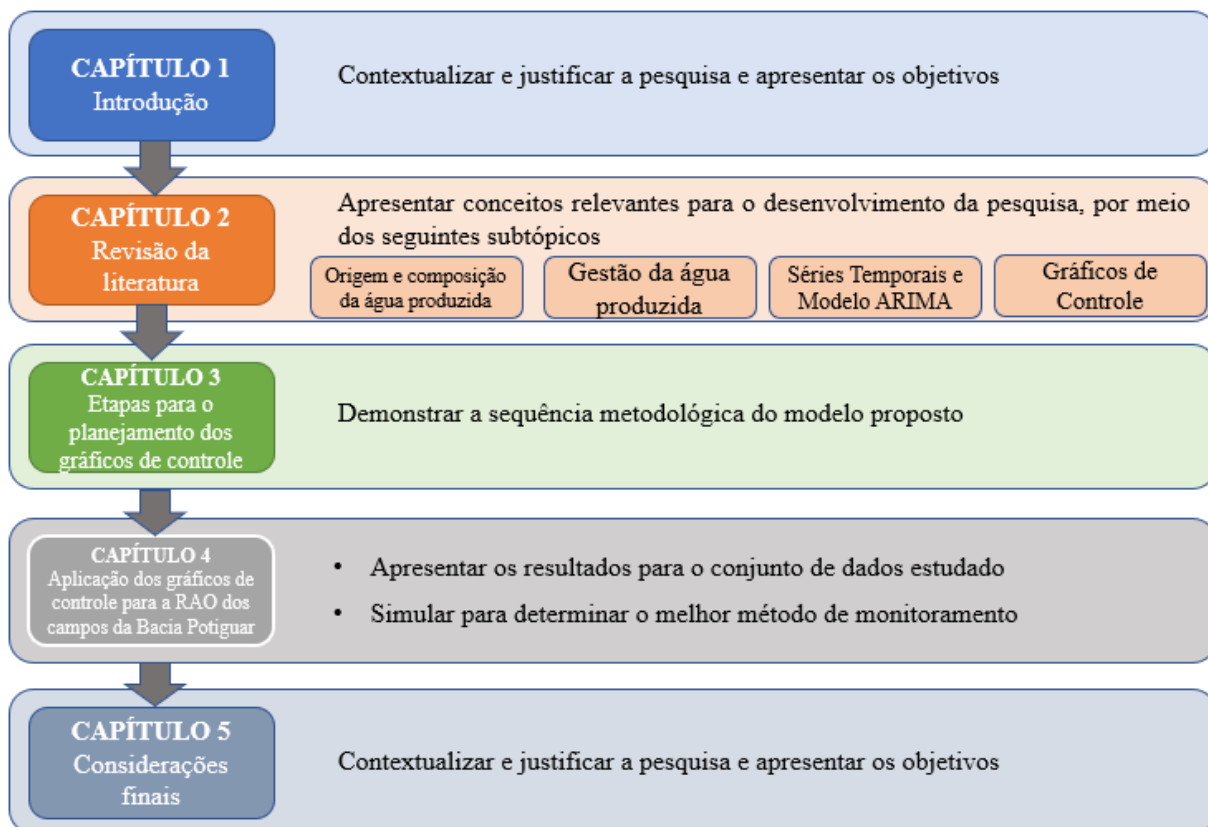
- d) Fornecer subsídios para a tomada de decisão acerca da viabilidade econômica de campos de Petróleo da Bacia Potiguar;

Frente ao exposto, os objetivos alinhados ao problema de pesquisa justificam-se pela lacuna na literatura brasileira e mundial, no que diz respeito aos estudos de desempenho da sustentabilidade ambiental em campos de petróleo considerando a geração de água produzida, sobretudo, por se tratar de uma pesquisa inédita e de cunho exploratório.

1.3 Estrutura da Tese

A tese é composta por cinco capítulos. O primeiro Capítulo é dedicado à introdução, onde está contextualizada a pesquisa bem como a justificativa para o estudo do tema e os objetivos propostos. Já o segundo Capítulo aborda a revisão da literatura acerca de temas relevantes para o desenvolvimento do modelo proposto. O terceiro Capítulo, por sua vez, discorre sobre as etapas necessárias para o desenvolvimento do modelo, apresentando a sequência metodológica e os materiais utilizados para que os resultados sejam obtidos. O quarto Capítulo expõe os resultados obtidos para o conjunto de dados estudado e traz uma simulação com o objetivo de comparar os métodos de monitoramento. E, por fim, o quinto capítulo traz as considerações finais, conclusões e sugestões para pesquisas futuras. Em resumo, a Figura 3, apresenta a estrutura da pesquisa.

Figura 3 - Resumo esquemático da estrutura da tese



Fonte: elaborado pela autora, 2018

2 REVISÃO DA LITERATURA

Este capítulo contará com uma breve revisão sobre temas que nortearam o desenvolvimento da pesquisa: a origem e composição da água produzida; a gestão da água produzida; séries temporais e modelos ARIMA; gráficos de controle.

2.1 Origem e Composição da Água Produzida

De acordo com Morad et al (2003), águas de formação podem ser originadas a partir de diversas fontes: águas conatas, águas oceânicas, águas oceânicas evaporadas, águas meteóricas, águas subterrâneas evaporadas ou ainda, águas magmáticas. As águas meteóricas fazem parte do ciclo hidrogeológico, que se movem da superfície para o fundo. Já as águas conatas são aquelas que se formam na parte inferior da terra, resultante de acumulação fóssil e que não tiveram contato com a atmosfera. Além disso, Morad et al. (2003) afirmam que boa parte da água de formação sofre interações com rochas, resultando em uma evolução de sua composição.

De acordo com Fakhru'l-Razi et al. (2009), as origens da água nos reservatórios podem ser apontadas, principalmente, de três formas:

- Fluxo de cima ou abaixo da zona de hidrocarboneto;
- Fluxo dentro da zona de hidrocarboneto;
- Fluxo de fluidos injetados e aditivos resultantes de atividades de produção.

Observa-se que, quando a produção do poço está sendo reduzida, ocorre o processo de recuperação secundária de petróleo, em que a água é reinjetada artificialmente, com o objetivo de manter as condições de pressão na rocha reservatório, forçando o petróleo a migrar, aumentando assim os níveis de produção.

Portanto, quando esta água, de diferentes origens, entra em contato com o poço, ela se eleva junto com os demais fluidos e passa a ser chamada de água produzida (abreviado em inglês como PW, de *produced water*).

De maneira geral, a origem básica da água produzida se funde com a origem do óleo nos reservatórios, sendo determinada pelas condições ambientais em que se encontram.

A composição natural da água produzida inclui basicamente uma grande quantidade de sais solúveis (carbonatos, sulfatos e cloretos de sódio, potássio, cálcio e magnésio) inerentes às formações geológicas em que elas se encontram. Além disso, esta água contém partículas de óleo em suspensão, compostos orgânicos e inorgânicos dissolvidos, sólidos suspensos (areia, lodo, argila, outros silicatos, gipsita) e produtos químicos adicionados nos diversos processos

de produção e/ou recuperação. Ou seja, essa água nada mais é que uma mistura de todas as formas resultantes da produção do petróleo.

A composição química da água produzida da formação depende fortemente do campo gerador do óleo, pois a água esteve em contato com as formações geológicas por milhões de anos. (CENPES, 2005).

Na prática, esta composição pode variar consideravelmente por diversas razões. Stewart e Arnold (2001) apontam dois fatores que influenciam de forma significativa as características físicas, químicas e biológicas da água produzida: a formação geológica e a localização geográfica do reservatório.

Além das características particulares de cada reservatório, em campos marítimos, a água produzida contém os mesmos sais e metais que a água do mar, mas em razões e concentrações diferentes. Swan et al. (1994) afirmam que a maioria dos metais encontrados na água produzida se encontram em concentrações maiores que os encontrados em água do mar.

Oetjen et al. (2018), afirmam que a água produzida são caracterizadas por química orgânica e inorgânica complexa e podem representar um risco à saúde se não forem manuseadas corretamente. Portanto, o tratamento e descarte adequados desta água é fundamental. Porém, os autores afirmam que, a variabilidade da composição química dessas águas ao longo do tempo é pouco compreendida e provavelmente limita a aplicabilidade de sua reutilização.

2.2 Gestão da Água Produzida

Thomas (2001) aponta que, no mundo, em média, a cada m³/dia de petróleo produzido, são gerados 3 a 4 m³ de água. Fakhru'l-Razi et al. (2009) corroboram esta afirmação e acrescentam ainda que a produção mundial de água produzida é estimada em cerca de 250 milhões de barris por dia, em comparação com cerca de 80 milhões de barris por dia de petróleo. Como resultado, a proporção de água para óleo é de cerca de 3:1.

Ao longo da exploração de petróleo de jazidas em terra (*onshore*) ou no mar (*offshore*), existe a geração concomitante de água produzida e esse tem sido a maior fonte de resíduos da indústria do petróleo.

Reynolds e Kiker (2003) realizaram um estudo onde apresentam as principais variáveis que influenciam no volume de água a ser produzida. Os autores apontam oito variáveis principais, que são:

- a) O método de perfuração dos poços: um poço horizontal pode produzir a uma taxa maior do que um poço vertical;

- b) Localização de poços dentro de reservatórios homogêneos ou heterogêneos: para reservatórios homogêneos, ou seja, que têm as mesmas propriedades em qualquer local, o uso de poços horizontais reduz a produção de água; o aumento na produção de poços horizontais versus verticais não estimulados é proporcional aos heterogêneos.
- c) Diferentes tipos de completação: o método de poço aberto permite o teste de zonas de perfuração e evita a perfuração em água. Por outro lado, o método de completação perfurada oferece um grau de controle muito mais elevado, uma vez que o intervalo de perfuração pode ser testado.
- d) Zona única e misturada: a maioria dos poços é inicialmente concluída em uma única zona. À medida que a taxa de óleo diminui devido ao amadurecimento do poço, outras zonas podem ser abertas para manter a taxa de produção de óleo. Como resultado, a produção de água também aumenta.
- e) Tipo de tecnologia de separação de água: diferentes métodos são utilizados para reduzir os custos de elevação e/ou manuseio de água para poços que produzem grandes quantidades de água salina. Estes métodos, geralmente, tratam do desligamento da água usando polímeros gelificados.
- f) Injeção de água para a recuperação de petróleo: o objetivo da injeção de água é aumentar o nível de óleo para aumentar a taxa de produção. Devido a esta injeção de água, uma porcentagem cada vez mais elevada da água é produzida.
- g) Má integridade mecânica: muitas entradas de água são causadas por problemas mecânicos causados pela corrosão ou pelo desgaste.
- h) Comunicações subterrâneas: problemas de comunicação subterrâneos costumam ocorrer perto de poços ou reservatórios. Estes problemas geram aumento da água produzida.

Além disso, a idade do poço também é determinante, uma vez que os níveis de óleo vão decaindo com o tempo e há uma maior necessidade de perfurar mais profundamente, aumentando a produção de água com o decorrer do tempo.

Clark e Veil (2009) apontam que em campos *offshore*, a maior parte da água produzida é tratada e descartada no mar. Já nos campos *onshore*, a maior parte do resíduo é aproveitada para injeção durante os processos de recuperação.

Desta forma, a gestão da água produzida é um problema inerente ao processo de produção do petróleo. Veil (2007) afirma que, como qualquer resíduo, a água produzida incorre em custos e precisa ser gerenciada. Além disso, vale salientar que a água produzida é o maior

resíduo da produção de petróleo. Assim, para a gestão da água produzida, o autor sugere uma hierarquia de prevenção de três níveis:

- I. Utilizar tecnologias para minimizar a produção de água;
- II. Reutilização e reciclagem;
- III. Se nenhum destes níveis for prático, a eliminação é a última opção.

Fakhru'l et al. (2009) apontam que devido ao crescente volume de resíduos em todo o mundo, o resultado e o efeito do descarte de água produzida no meio ambiente tornaram-se uma questão significativa de preocupação ambiental. Os autores apontam ainda que os custos de tratamentos são elevados e produzem resíduos perigosos.

Clark e Veil (2009) afirmam que os custos de gerenciamento de tão elevado volume de água residual é uma questão chave para os produtores de petróleo e gás e, por isso, afetam diretamente a decisão da continuidade dos campos de produção. Assim, pode-se afirmar que quando o custo de gerenciar a água produzida ultrapassa os ganhos da venda do óleo, o poço deixa de ser viável.

Segundo Oliveira (2008), esta viabilidade também pode ser medida pela quantidade de água produzida associada ao óleo, alcançando valores da ordem de 5% em volume, no início da produção, ou até mesmo atingindo valores bastante próximos de 100% ao fim da vida econômica do poço.

Cada país possui sua legislação específica para o tratamento e descarte da água produzida. Essas leis versam sobre os valores de teor de óleos e graxas (TOG) presentes na água. Na Austrália, por exemplo, os valores regulados são de média diária de 30 ppm (partes por milhão), com um máximo de 50 ppm; já no Mar do Norte, Mediterrâneo, Golfo Árabe e Ásia, os valores têm como meta média 30 ppm; já os Estados Unidos exigem uma média mensal de 29 ppm, com valores diários máximos de 42 ppm. (ELPN/IBAMA, 2006).

No Brasil, a Resolução CONAMA nº 357, de 17 de março de 2005, definiu no inciso 4º, Artigo 43, a necessidade de uma resolução que tratasse especificamente do descarte contínuo da água produzida no mar, visto que 80% do petróleo do país é produzido offshore. O valor a ser respeitado para o descarte contínuo de água produzida é o de 20 ppm para o TOG (ELPN/IBAMA, 2006). Já a Resolução nº 430, de 13 de maio de 2011 complementa a nº 357, apresentando as condições necessárias para o lançamento de efluentes visando uma redução no impacto ambiental, como temperatura e pH ideais, além de outros aspectos técnicos a serem considerados.

Há diversos estudos na área de gerenciamento da água produzida voltados para o tratamento e destinação da água (métodos de separação, caracterização química e métodos de descarte, por exemplo). Porém, a literatura que trata do monitoramento contínuo do volume produzido desta água ainda é escassa, bem como as abordagens que relacionam o custo deste resíduo.

2.3 Séries Temporais e Modelos Arima

Morettin e Toloi (2004) definem as séries temporais como sendo qualquer conjunto de observações ordenadas no tempo. Os autores apontam ainda algumas características particulares deste tipo de dados, como por exemplo:

- a) As observações estão correlacionadas, o que faz com que as análises sejam feitas por meio de técnicas específicas;
- b) É preciso levar em conta a ordem temporal de ocorrência das observações;
- c) Fatores complicadores, como presença de tendências e variação sazonal ou cíclica podem ser difíceis de estimar ou remover;
- d) A seleção de modelos nem sempre é simples;
- e) É mais difícil lidar com observações perdidas e dados discrepantes devido à natureza sequencial.

Maddala e Lahiri (2009) afirmam que o propósito da análise de séries temporais é estudar a dinâmica e a estrutura temporal dos dados. Em resumo, os autores definem as séries temporais como sendo uma coleção de observações indexadas pela data de cada observação (equação 1), isto é:

$$\{y_t\}_{t=-\infty}^{\infty} = \{\dots, y_{-1}, y_0, y_1, y_2, \dots, y_T\} \quad (1)$$

Já Morettin e Toloi (2004), apontam como os objetivos principais do estudo das séries temporais como sendo quatro:

- Investigar o que gera a série temporal;
- Fazer previsões de valores futuros da série;
- Descrever o comportamento da série, bem como suas características, e
- Buscar periodicidades relevantes nos dados.

Uma série temporal é estacionária quando suas características estatísticas (média, variância, autocorrelação) não variam ao longo do tempo. Estas séries têm comportamento aleatório no tempo, variando em torno de uma média constante, refletindo um comportamento estável.

Porém, em casos práticos, a maioria das séries possui um comportamento não estacionário. Desta forma, os métodos de previsão utilizam artifícios e transformações matemáticas buscando tornar as séries estacionárias para fazer previsões a partir dela (MADDALA E LAHIRI, 2009). As transformações mais comuns são tomar diferenças sucessivamente da série original, deflacionar, aplicar funções matemáticas (como logaritmo, por exemplo), entre outras.

A análise de uma série temporal modela o fenômeno estudado para, a partir daí descrever o comportamento (sistemático e com um padrão persistente) da série, fazer estimativas e, por último, avaliar quais os fatores que influenciaram o comportamento da série, buscando definir relações de causa e efeito entre duas ou mais séries. (MORETTIN E TOLOI, 2004).

Guanieri et al. (2009) explicam que os modelos de ajuste baseados em séries temporais são:

- AR (p), de autorregressivo, em que a série é descrita por seus valores passados regredidos e pelo ruído aleatório;
- MA (q), de média móvel, que explora a estrutura de autocorrelação dos resíduos de previsão do período atual com aqueles ocorridos em períodos anteriores e;
- ARMA (p, q), que representam processos mistos, apoiando-se na premissa que a série temporal é estacionária.

Os modelos autorregressivos consideram que o valor atual da série é uma combinação linear dos p valores passados da série e de um ruído branco (BOX, JENKINS E REINSEL, 1994). Já nos modelos de médias móveis, o valor atual da série é uma média ponderada dele próprio mais os q últimos valores de um processo ruído branco (MORETTIN E TOLOI, 2004).

Quando a série é não-estacionária, além dos modelos citados, é utilizada a componente de integração I (d), compondo o modelo ARIMA.

Box e Jenkins (1976) reuniram as técnicas de ajuste existentes numa metodologia para construir modelos que descrevessem com precisão o processo gerador da série temporal, proporcionando, dessa forma, previsões acuradas de valores futuros. Esta metodologia busca o ajuste de um modelo autorregressivo integrado de médias móveis, ARIMA (p, d, q), a um conjunto de dados.

Guanieri et al. (2009) afirmam que a metodologia de ajuste de modelo, que acabou se tornando conhecida como método *Box-Jenkins*, é composta por um ciclo com três etapas iterativas: identificação do modelo, estimativa dos parâmetros e diagnóstico do modelo. Morettin e Toloi (2004) acrescentam uma etapa inicial, realizada antes da identificação, a que chamam *especificação*, que consiste em caracterizar os dados dentro de uma classe geral de modelos.

Segundo Gujarati (2006), os modelos ARIMA analisam as propriedades estocásticas ou probabilísticas das séries temporais, sendo representado por ARIMA (p, d, q), onde p é o número de termos autorregressivos do modelo; d , o número de vezes que devemos diferenciar a série antes que ela se torne estacionária e q , o número de termos de médias móveis, sendo p , d e q inteiros maiores ou iguais a zero.


Morettin e Toloi (2004) apresentam um procedimento geral para a identificação do dos valores de p , d e q do modelo ARIMA (p, d, q) que consiste em três passos:

- I. Verificar a necessidade de transformar os dados da série original, com o objetivo de buscar a estacionariedade;
- II. Tomar as diferenças da série tantas vezes forem necessárias para se obter uma série estacionária. Esta etapa determina o valor de d no modelo;
- III. Identificar o processo ARMA (p, d) resultante, através da análise das autocorrelações e autocorrelações parciais.

Pode-se afirmar que a etapa de identificação do modelo depende diretamente da análise das autocorrelações e autocorrelações parciais dos dados. A autocorrelação é a dependência temporal entre os valores de uma série. A função de autocorrelação mede o grau de correlação de uma variável, em um dado instante, consigo mesma, em relação a um instante de tempo posterior. Já a função da autocorrelação parcial é obtida por meio de um gráfico da autocorrelação em função da defasagem. A interpretação do correlograma serve de subsidio no processo de identificação do modelo.


A série é considerada estacionária quando, no correlograma, há alteração abrupta de direção ou um padrão de decaimento rápido (Figuras 4 e 5).

Figura 4 - Exemplo de Correlograma com Mudança Abrupta de Direção



Fonte: Morettin e Toloí (2004)


Figura 5 - Exemplo de Correlograma com Decaimento Rápido dos Valores Significativos



Fonte: Morettin e Toloí (2004)

A leitura do correlograma permite ainda a identificação de séries não estacionárias. Nestas, o decaimento dos valores significativos é lento, assim como as mudanças de direção, como pode ser visualizado na Figura 6.

Figura 6 - Exemplo de Correlograma com Decaimento Lento (Série não estacionária)




Fonte: Morettin e Toloí (2004)

Como exemplos de padrão de decaimento das séries estacionárias, podem ser observados os padrões representados na Figura 7, em que:

- a) decaimento exponencial sem oscilações;

- b) decaimento exponencial com oscilações;
- c) decaimento em onda senoidal.

Figura 7 - Exemplos de Padrões de Decaimento



Fonte: Morettin e Toloi (2004)

Tendo-se identificado o modelo da série temporal, o próximo passo é estimar os parâmetros que irão caracterizar este modelo. Morettin e Toloi (2004) afirmam que será necessário usar um procedimento iterativo de estimação não-linear dos mínimos quadrados e as estimativas preliminares encontradas na fase de identificação serão utilizadas como valores iniciais neste procedimento. Porém, na prática, esta etapa tem sido realizada por meio de programas computacionais, que já incorporam estes valores iniciais.

Após as etapas de identificação e estimação, deve-se realizar o diagnóstico do modelo, que consiste em avaliar se este representa adequadamente o conjunto de dados. Morettin e Toloi (2004) apontam que uma técnica que pode ser utilizada é a de *superajustamento* em que é estimado um modelo com parâmetros extras e examinamos se estes são significativos.

Além deste método, a análise dos resíduos se faz importante na etapa de diagnóstico. Uma vez ajustado o modelo ARIMA, deve-se realizar um teste para analisar a normalidade dos resíduos, pois esta é uma forma de verificar a adequação do modelo: quando o modelo está satisfatório, os resíduos resultantes serão normalmente distribuídos. Para isto, existem vários

testes e um deles é o Shapiro e Wilk (Shapiro-Wilk, 1965). Esse teste é eficiente para diferentes distribuições e tamanhos de amostras quando comparado aos resultados de outros testes.

Estes conceitos se tornam importantes para o modelo proposto, pois se observa que os dados referentes à RAO possuem autocorrelação diferente de zero. Para o uso dos gráficos de controle, se faz necessário ajustar um modelo de séries temporais, neste caso, o modelo escolhido foi o ARIMA (WOODALL e MONTGOMERY, 1999). Quando o modelo ARIMA é ajustado e os resíduos são normalmente distribuídos, aplicam-se os gráficos de controle a estes resíduos para fins de monitoramento.

2.4 Gráficos de Controle

De maneira geral, os processos produtivos devem operar com pequena variabilidade natural em torno de dimensões-alvo ou características específicas. Portanto, as ferramentas que compõe o chamado controle estatístico de processos, se apresentam como poderosas ferramentas na manutenção da variabilidade.

Montgomery (2001), afirma que o gráfico de controle é um artifício para descrever visualmente o controle estatístico. Uma vez que eles podem ser usados para uma vigilância contínua dos processos, facilitando a detecção de descontroles.

Os gráficos de controle foram propostos inicialmente por Shewhart (1931) e se destinam a examinar se o processo está ou não sob controle estatístico. Em resumo, esta ferramenta de monitoração sintetiza os dados, usando métodos estatísticos para observar o comportamento do processo e indicando uma situação de controle ou não do mesmo.

De acordo com Montgomery e Runger (2003), o objetivo principal do gráfico de controle é diferenciar a ocorrência de causas especiais, que provocam mudanças importantes no processo, dos desvios provocados por causas comuns ou aleatórias.

Um gráfico de controle tradicional é composto de três linhas paralelas: uma linha média que reflete o nível esperado de operação do processo, e duas linhas externas denominadas: limites superior de controle (LSC) e limite inferior de controle (LIC), calculados em função do desvio padrão de alguma variável ou atributo do processo de modo a satisfazer alguma métrica de desempenho (SHEWHART, 1931). Assume-se que um processo está em controle estatístico quando todos os pontos plotados se encontram entre estes limites. Já quando se encontra um ponto fora desses limites, assume-se que é necessário intervir no processo, pois se assume que alguma causa especial ocorreu, retirando-o do estado de controle.

Montgomery (2001) define ainda o controle estatístico de qualidade (CEQ) como sendo uma técnica que consiste em analisar o processo, estabelecer padrões, comparar desempenhos, verificar e estudar desvios, buscar e implementar soluções e analisar novamente o processo, após as modificações, buscando a melhor performance de máquinas e/ou pessoas.

A determinação dos limites de controle influencia diretamente as probabilidades de ocorrência dos erros tipo I (α) e tipo II (β). O erro tipo I, ou probabilidade de alarme falso, ocorre quando um ponto é plotado fora dos limites de controle com o processo em controle. Já o erro tipo II ocorre quando os pontos estão dentro dos limites com o processo fora de controle. Os limites são tradicionalmente determinados conforme descritos nas equações 2 e 3:

$$LIC = \bar{X} - Z_{\alpha/2} \sigma \quad (2)$$

$$LSC = \bar{X} + Z_{\alpha/2} \sigma \quad (3)$$

Em que a variável \bar{X} corresponde a valor médio da medida de interesse das observações; $Z_{\alpha/2}$ representa o valor padronizado da distribuição normal que resulta na probabilidade de erro tipo I (α) desejada; e, por fim, σ é o desvio padrão da amostra.

Os gráficos de controle são, portanto, ferramentas visuais para o monitoramento de medidas de interesse. Sua importância reside no fato de que, uma vez que eles sejam planejados corretamente, o seu uso é simples.

Costa et al. (2008) apontam que os gráficos de controle tradicionais (gráficos tipo Shewhart) são eficientes para detectar grandes desvios. Porém, à medida que os processos ficam mais robustos (com menos causas especiais), estes gráficos perdem a eficiência.

Neste cenário, o Gráfico de Controle das Somas Acumuladas (CUSUM) e o Gráfico de Controle da Média Móvel Ponderada Exponencialmente (EWMA) se apresentam como alternativas adequadas.

Neste contexto, Costa et al. (2008) afirmam que quando se usa o CUSUM ou o EWMA, a decisão sobre o estado do processo é baseada na informação acumulada das amostras e não apenas na última delas. Assim, consegue-se maior rapidez na detecção de pequenos desvios.

Os gráficos de controle de somas cumulativas foram inicialmente propostos por Page (1954) e Montgomery (2001) apresenta como destaque do gráfico CUSUM o fato dele incorporar diretamente toda a informação da sequência de valores amostrais através da soma cumulativa dos desvios destes valores em relação a um valor alvo, não apenas a informação do último ponto plotado, como nos gráficos tradicionais. Este gráfico incorpora toda a informação

na sequência de valores da amostra, pois são plotadas as somas cumulativas dos desvios. Suponha que i amostras de tamanho $n=1$ sejam coletadas e que x_i seja a i -ésima observação, sendo x_0 é o valor alvo, o gráfico de controle será plotado considerando a equação 4.

$$C_i = \sum_{1}^i (x_i - x_0) \quad (4)$$

Com o processo em controle, os valores da soma serão continuamente compensados por aumentos e reduções aleatórias em torno do alvo. Porém, um descontrole rapidamente direcionará a média para fora dos limites.

O monitoramento por meio do CUSUM foi realizado considerando o gráfico de CUSUM Tabular, descrito por Montgomery (2001). Este procedimento considera intervalos bilaterais (equações 5 e 6) simétricos que utiliza duas estatísticas unilaterais (C_i) para a comparação, visando detectar mudanças positivas ou negativas separadamente:

$$C_i^+ = \max[0, x_i - (\mu_0 + K) + C_{i-1}^+] \quad (5)$$

$$C_i^- = \max[0, (\mu_0 + K) - x_i + C_{i-1}^-] \quad (6)$$

A variável K é o valor de tolerância que, normalmente, representa o ponto médio entre o valor alvo (μ_0) e a média do processo fora de controle (μ_1) que se quer detectar. Se as estatísticas C_0^+ ou C_0^- exceder o intervalo de decisão H , o processo é considerado fora de controle. Um valor razoável para H é quatro ou cinco vezes o valor do desvio padrão σ , isto é, $H=4\sigma$ ou 5σ .

Porém, os gráficos de controle tradicionais são habitualmente planejados e avaliados, assumindo que observações consecutivas do processo são independentes e identicamente distribuídas (i.i.d.), entretanto esta hipótese é frequentemente violada na prática, pois a maioria dos processos apresenta autocorrelação (MONTGOMERY, 2001).

Cabe avaliar se a autocorrelação é provocada por uma causa especial, e, se sim, deve ser eliminada. No caso dela ser inerente ao conjunto de dados, deve-se levá-la em consideração no planejamento dos gráficos de controle, evitando-se planejamento errado dos seus parâmetros, que resultam, como uma das consequências, em aumento na taxa de alarmes falsos ou no número de amostras necessárias para detecção de deslocamentos na média do processo

(VANDER WIEL, 1996; REYNOLDS e LU, 1997; VAN BRACKLE, III; REYNOLDS, 1997; LU; REYNOLDS, 1999).

Maragah (1992) mostra que a presença de autocorrelação positiva na primeira defasagem resulta em um aumento no número de falsos alarmes do gráfico de controle. Já a autocorrelação negativa na primeira defasagem pode resultar em limites de controle desnecessariamente amplos, de forma que mudanças significativas na média do processo podem passar despercebidas.

Com o objetivo de reduzir o número de alarmes falsos, Osei-Aning, Abbasi e Riaz (2017) propuseram que os limites de controle dos gráficos EWMA e CUSUM sejam obtidos por meio de otimização através de busca exaustiva dos parâmetros ideais que minimizem a perda quadrática extra para cada coeficiente de autocorrelação.

Dawod, Riaz e Abbasi (2017), afirmam que para dados autocorrelacionados é importante escolher um modelo adequado para diferentes tipos de cartas de controle para modelos de séries temporais. O estudo propõe comparar três tipos populares de gráficos: Shewhart, média móvel exponencialmente ponderada e soma cumulativa, incluindo modelos AR (1), MA (1) e ARMA (1,1). Para isso, são testados aspectos de eficiência e robustez para um conjunto real de dados.

Diversos trabalhos apontam que, nos casos de dados autocorrelacionados, é possível ajustar um modelo de previsão às observações e realizar o monitoramento do processo com gráficos de controle para os resíduos i.i.d. resultantes. (MONTGOMERY E MASTRANGELO, 1991; SUPERVILLE E ADAMS, 1994; ZHANG, 1997; ENGLISH et al., 2000; KOEHLER et al., 2001; TESTIK, 2005).

Desta forma, justifica-se o ajuste de um modelo ARIMA adequado aos dados, com o objetivo de remover a autocorrelação e obter os resíduos independentes, e, a partir destes resíduos, aplicar um tipo de gráfico de controle (gráfico para a média, CUSUM, EWMA, entre outros) para então, monitorar o processo com as técnicas convencionais de CEP.

Alwan e Roberts (1988) decompõem os dados através da análise de regressão, em que os valores plotados são os valores do modelo ARIMA ajustado, e os resíduos são a diferença entre os valores reais e os ajustados, que serão monitorados. Neste trabalho, os gráficos dos resíduos são chamados de gráfico de causas especiais, SCC (*Special Cause Chart*), pois permite detectar os desvios do processo.

Já Runger (2002) promoveu uma discussão sobre que tipo de gráfico de controle utilizar no caso de dados com autocorrelação: gráficos para observações ou para resíduos. Ele apresenta situações em que o gráfico para observações possui desempenho tão eficaz quanto o gráfico

para resíduos. Neste trabalho, o autor compara o gráfico para os resíduos com gráficos para as observações tratadas como médias ponderadas de subconjuntos de dados (WBM - *weighted batch mean*) e gráfico usando médias não ponderadas de subconjuntos de dados (UBM - *unweighted batch mean*). Este terceiro não requer nenhum modelo de séries temporais, uma vez que simplesmente traça médias aritméticas de valores consecutivos de dados (a autocorrelação é diminuída escolhendo uma amostra suficientemente grande). Como resultados, o autor observou que os gráficos que consideram as médias podem ter melhor desempenho do que os gráficos de resíduos para dados AR (1).

Nesta mesma linha, o trabalho de Claro et al. (2007) aborda o monitoramento de processos autocorrelacionados com observações coletadas em subgrupos racionais. O estudo desenvolve ainda uma análise comparativa entre os desempenhos do gráfico X, EWMA e CUSUM. A medida utilizada foi a quantidade de alarmes falsos gerados e como conclusão foi apresentado o gráfico EWMA como o de maior poder de detecção nos casos estudados.

Urbietta et al. (2016) também demonstraram que o gráfico EWMA apresenta melhor desempenho do que CUSUM principalmente para pequenas mudanças, como no máximo 25% de aumento na média do processo.

Osei-Aning et al. (2017) apontam que há uma dificuldade na escolha de parâmetros para os gráficos tradicionalmente usados e propõe uma metodologia para determinação dos parâmetros ótimos, usando um procedimento de busca exaustivo.

Tradicionalmente, os gráficos de controle para médias consideram apenas uma medida no monitoramento. Porém, este trabalho propõe o monitoramento da razão entre duas variáveis (produção de água e produção de óleo).

A aplicação dos gráficos de controle para razão entre duas variáveis é um estudo relativamente recente. Celano e Castagliola (2016) discutem a importância de alternativas para monitoramento da razão entre duas variáveis aleatórias, propondo um gráfico chamado RZ-Shewart, baseado na razão entre duas variáveis normais retiradas de uma amostra. Além disso, Mousavi e Reynolds (2009) já haviam proposto um gráfico CUSUM binário de Markov (chamaram de MBCUSUM) para monitoramento de proporções quando há um fluxo contínuo de observações binárias autocorrelacionadas que seguem um modelo de cadeia de Markov de dois estados.

Tran e Knoth (2018) propõem um gráfico de controle EWMA não homogêneo para o monitoramento da razão de duas variáveis normais. São propostos três gráficos para o gráfico de controle EWMA-RZ bilateral: limites de controle simétricos, limites probabilísticos para caudas iguais e ARL imparcial.

Assunção, Vieira e Ho (2018) aplicam a metodologia proposta em dois campos de petróleo da Bacia Potiguar para avaliar os gráficos Shewhart e CUSUM no monitoramento da razão água-óleo. Este artigo é resultante do trabalho desenvolvido nesta tese.

3 ETAPAS PARA O PLANEJAMENTO DOS GRÁFICOS DE CONTROLE

Neste capítulo serão expostas a área de abrangência dos dados, bem como as etapas percorridas para o desenvolvimento do modelo.


3.1 Área de Abrangência do Estudo

A metodologia proposta para o monitoramento da razão água-óleo está baseada na análise do conjunto dos dados de produção mensal de água e óleo nos campos da Bacia Potiguar entre os anos de 2006 e 2015. A coleta destes dados foi realizada por meio dos anuários disponibilizados pela ANP e posteriormente foram tratados e organizados. Após esta etapa, foi possível calcular os valores da razão água-óleo mensal para cada um dos campos e esta será a variável de interesse do modelo.

Tal variável foi escolhida por se tratar de uma medida que torna possível a comparação entre os campos, independentemente da discrepância entre a capacidade produtiva deles. Além disso, uma decisão sobre esta medida fornece subsídios do ponto de vista econômico sobre a viabilidade dos campos de produção, uma vez que um grande volume de água produzida, em detrimento o volume de óleo, torna o campo pouco rentável.

A amplitude geográfica dos dados estudados atinge os campos da Bacia Potiguar. Tal Bacia engloba todo estado do Rio Grande do Norte e parte do Ceará, abrangendo uma área estimada em aproximadamente 94.043 Km². Ela está localizada no extremo nordeste do Brasil limitando-se, a leste, pelo Alto de Touros (mar) e plataforma de Touros (terra) com a Bacia de Pernambuco-Paraíba; a noroeste, pelo Alto de Fortaleza (mar) e plataforma Aracati (terra) com a Bacia do Ceará; a sul, com embasamento cristalino; e, a norte, com o oceano atlântico, ocorrendo até a cota batimétrica de 200m, como pode ser visualizado na Figura 8.

Figura 8 - A Bacia Potiguar



Fonte: ANP (2016)

A exploração de hidrocarbonetos na Bacia Potiguar teve início em 1949, com mapeamentos de superfície e levantamentos gravimétricos e magnetométricos conduzidos pelo Conselho Nacional do petróleo (CNP). A produção teve início em 1956 já sob a atuação da Petrobras.

Segundo a ANP, em 2017 a Bacia Potiguar contava com 94 campos de produção e em desenvolvimento produzindo um total de 47.715 bbl/dia de petróleo e 1.143 m³/dia de gás natural. Historicamente, esta bacia está entre os maiores produtores de petróleo em terra do Brasil, porém, atualmente, a exploração de óleo ocorre majoritariamente a partir campos maduros.

É sabido que os campos maduros possuem uma maior produção de água em relação aos campos novos devido à natureza do processo de exploração. Desta forma, foi realizado um recorte, para fins de modelagem, de uma amostra com base na idade destes campos. Este recorte foi realizado com o objetivo de obter uma amostra com características mais homogêneas em relação à variável de interesse, que, de acordo com a bibliografia, é influenciada diretamente pela idade do campo.

Nesta etapa de formação da amostra, foram selecionados os campos com idade de operação superior a quinze anos, que possuem dados com comportamento que possibilitasse a modelagem. Tentou-se realizar uma modelagem para todos os campos da Bacia Potiguar considerados maduros, porém para alguns dos campos, os dados não foram possíveis de serem modelados a partir da metodologia proposta (o modelo proposto não se adequou ao comportamento destes), sendo então retirados da amostra.

Ao final da etapa de formação da amostra, restaram dezoito campos, sendo todos eles *onshore*. Os nomes dos campos foram suprimidos na exposição dos resultados.

A Tabela 2 apresenta os campos terrestres selecionados para a aplicação da metodologia e as suas respectivas idades de operação.

Tabela 2 - Campos *onshore* (suas idades, em meses) selecionados para a realização da pesquisa

CAMPO	IDADE (em 31/12/2017)
A	370 meses
B	383 meses
C	323 meses
D	361 meses
E	336 meses
F	348 meses
G	384 meses
H	432 meses
I	279 meses
J	455 meses
K	265 meses
L	302 meses
M	312 meses
N	397 meses
O	365 meses
P	422 meses
Q	372 meses
R	387 meses

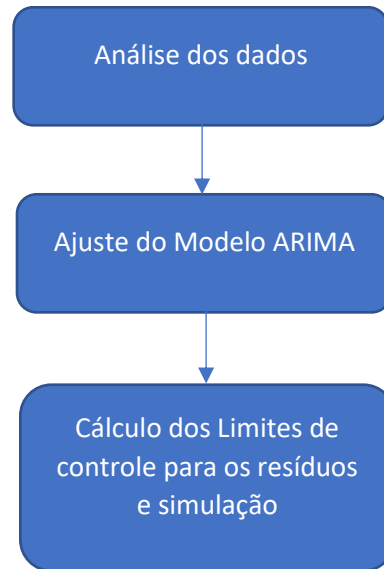
Fonte: elaborada pela autora

3.2 Etapas do Modelo Proposto

Uma vez selecionados os campos, foi calculada a razão água-óleo mensal para cada um deles. As etapas de ajuste do modelo, bem como a monitoração proposta, foram realizadas com base nestes valores históricos da razão.

As análises a partir dos dados da razão foram realizadas com o apoio do software R, sendo utilizados os pacotes *tseries* e *forecast* para a análise de séries temporais e *qcc* para a determinação dos limites de controle. Os algoritmos utilizados estão expostos no Apêndice A. De maneira geral, o modelo proposto se divide em três etapas principais, descritas na Figura 9.

Figura 9 - Resumo das etapas do modelo



Fonte: elaborada pela autora (2017)


3.2.1 Análise dos dados

Inicialmente, analisou-se a série temporal resultante dos dados da razão mensal. Com base nestes valores, foram obtidas as funções de autocorrelação e autocorrelação parcial, a fim de avaliar a estacionariedade destas séries.

Corroborando com a bibliografia, com base na tendência natural de aumento desta razão com o passar o tempo, as séries encontradas não são estacionárias. Morettin e Tolo (2004) apontam a necessidade de realizar transformações a fim de buscar a estacionariedade dos dados para análise e os autores sugerem que se façam sucessivas diferenciações dos dados. A primeira transformação testada foi a primeira diferença dos dados da razão.

Para alguns campos, foi necessário realizar um recorte no conjunto de dados, na busca pela estacionariedade. Desta forma, considerou-se apenas um subconjunto sequencial desses dados que permitiu a obtenção da série estacionária por meio da primeira diferença. Além disso, esse ajuste é necessário para que os limites sejam estabelecidos com o processo em controle estatístico. Para exemplificar, a Figura 10 apresenta o recorte temporal realizado no Campo B:

Figura 10 - Exemplo do recorte temporal realizado



Fonte: elaborada pela autora (2017)

Este procedimento foi adotado em onze campos que apresentaram uma maior dificuldade de obtenção da série estacionária. Tabela 3 apresenta a lista dos campos onde os dados foram recortados.

Tabela 3 - Campos em que foram realizados recortes temporais

Campo	Quantidade de dados da série resultante
B	76 dados
C	59 dados
E	51 dados
F	109 dados
H	110 dados
J	69 dados
K	79 dados
L	59 dados
M	35 dados
P	77 dados
Q	80 dados
R	59 dados

Fonte: elaborada pela autora (2017)

Para os demais campos não citados, foram utilizados todos os 120 dados resultantes da razão água-óleo entre 2006 e 2015.

Após esta etapa, os dados transformados foram submetidos a uma nova análise da autocorrelação e autocorrelação parcial para avaliar se a estacionariedade da série havia sido atingida.

3.2.2 Ajuste do Modelo ARIMA

Com as séries estacionárias, após a transformação aplicada, ajustou-se o modelo ARIMA para cada um dos campos, a fim de determinar os limites com base nos resíduos deste modelo.

A etapa de identificação do modelo foi baseada no comportamento das funções de autocorrelação e autocorrelação parcial, para encontrar as ordens dos termos autorregressivos e de média móvel para cada um dos campos.

Além disso, para que um modelo ARIMA fosse definido, foram realizadas sucessivas combinações dos parâmetros (p, d, q) e a normalidade dos resíduos foram testadas em cada

modelo por meio do teste de Shapiro-Wilks. Apenas os modelos com evidências significativas da normalidade dos resíduos foram considerados.

Modelos mais simplificados (e com um número pequeno de termos) foram ajustados em dados de alguns campos, enquanto outros exigiram modelagens mais complexas e, conseqüentemente, em um modelo com mais termos autorregressivos e de média móvel. Estas diferenças poderão ser visualizadas com mais detalhes no Capítulo 4.

Assim, cada um dos campos estudados foi ajustado a um modelo específico e a normalidade dos resíduos foi então testada para validá-los. Observa-se que, de maneira geral, modelos mais simples obtiveram um nível descrito maior em relação ao teste de normalidade que os modelos mais complexos.

3.2.3 Determinação dos Limites de Controle e Simulação

Ao modelar dados, são gerados resíduos, resultantes da diferença dos valores previstos pelo modelo e os valores reais. Desta forma, de posse dos resíduos de cada modelo ajustado, os limites de controle para a razão água-óleo de cada um dos campos foram determinados. Esses limites foram definidos considerando as observações individuais dos resíduos dos modelos mensais da RAO.

Neste trabalho serão considerados dois tipos gráfico com o objetivo de comparação: gráfico de Shewhart e o gráfico CUSUM. Gráfico de controle foram aplicados com o objetivo de avaliar se os valores de RAO se mantêm estáveis ou se desviaram do valor alvo.

Para comparar os desempenhos de diferentes gráficos, uma das medidas utilizada é o número médio de amostras até a sinalização. É desejável que quando uma mudança acontecer, ela seja sinalizada rapidamente. Assim, será considerado o melhor gráfico aquele que tiver o menor número médio de amostras até a sinalização.

O valor de $Z_{\alpha/2}$ é uma etapa importante da determinação dos limites de controle. Os gráficos tradicionais de Shewhart consideram $Z = 3$ desvios. O número médio de amostras (NMA) até um sinal, estando o processo em controle (alarme falso) é de:

$$NMA = \frac{1}{\alpha} = \frac{1}{0,0027} \cong 370 \text{ amostras} \quad (7)$$

Porém, considerando que os dados estudados são mensais, não faria sentido aguardar todos estes meses até uma detecção de descontrole. Para tanto, foram utilizados limites menores

para que a detecção do descontrole ocorra de forma mais rápida. Foi fixado o número máximo de observações ($NMA_{m\acute{a}x}$) até o sinal em 60 (meses) e determinado os limites de controle considerando este critério. Sendo, $NMA_{m\acute{a}x} = 60$, tem-se $\alpha = 0,0167$. Portanto, $Z_{\alpha/2} = 2,39$ e os limites superiores e inferiores, respectivamente, serão determinados pelas equações 8 e 9:

$$LSC = X_i + 2,39\sigma \quad (8)$$

$$LIC = X_i - 2,39\sigma \quad (9)$$

Para determinação dos limites do CUSUM, foram coletadas as sucessivas observações individuais relativas aos resíduos do modelo para a obtenção da estatística dos desvios de cada um dos valores em relação à medida alvo (valor central = 0), conforme descrito na equação (10).

$$C_i = \sum_{1}^i (x_i - \mu_0) \quad (10)$$

Os limites de controle para o Gráfico CUSUM, por sua vez, foi elaborado a partir de sucessivos testes de valores de H que resultassem em um número máximo de observações até o sinal ($NMA_{m\acute{a}x}$) de 60.

Além disso, devido à complexidade de obter uma expressão fechada para esta métrica, uma busca extensiva, por meio de simulação, foi realizada a fim de avaliar o desempenho dos gráficos com relação ao poder de detecção de mudança no valor dos parâmetros de cada um dos campos, conforme o seguinte procedimento:

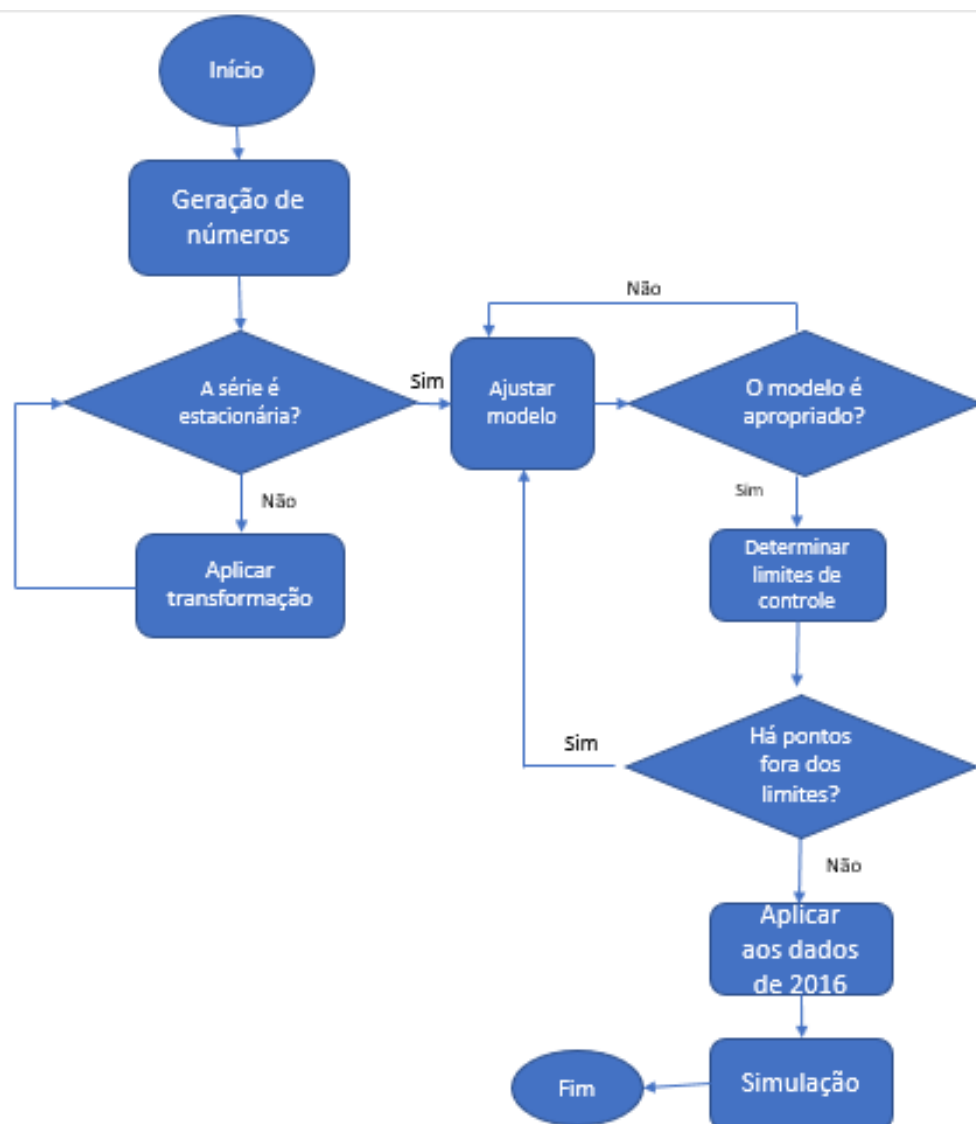
- a) Passo 1: Gerar 2000 observações aleatórias segundo uma distribuição de probabilidade normal, considerando os parâmetros encontrados para cada um dos campos. Além disso, foram gerados valores aleatórios considerando desvios de 10%, 50%, 100% e 200% em relação aos valores da média;
- b) Passo 2: Examinar sequencialmente se a observação gerada está dentro dos limites de controle até a ocorrência de uma amostra fora dos limites de controle (sinalização de descontrole);
- c) Passo 3: Armazenar o número de amostras até a ocorrência da sinalização e volte para o passo 1. Repetir este procedimento 5000 vezes;
- d) Passo 4: Calcular o número médio de amostras até a sinalização.

Os limites foram, então, aplicados aos dados de 2016, sendo estes modelados a partir dos mesmos parâmetros do modelo ARIMA ajustado aos dados do campo, a fim de se obter os resíduos.

O Apêndice A traz os programas utilizados para a análise dos dados, determinação dos modelos e limites dos gráficos de controle para os campos estudados.

De maneira geral, a metodologia de monitoração proposta pode ser resumida por meio do fluxograma exposto na Figura 11.

Figura 11 - Fluxograma da metodologia proposta



Fonte: elaborada pela autora

4 APLICAÇÃO DOS GRÁFICOS DE CONTROLE PARA A RAO DOS CAMPOS DA BACIA POTIGUAR

Neste capítulo estarão descritos os resultados obtidos a partir das etapas do modelo proposto.

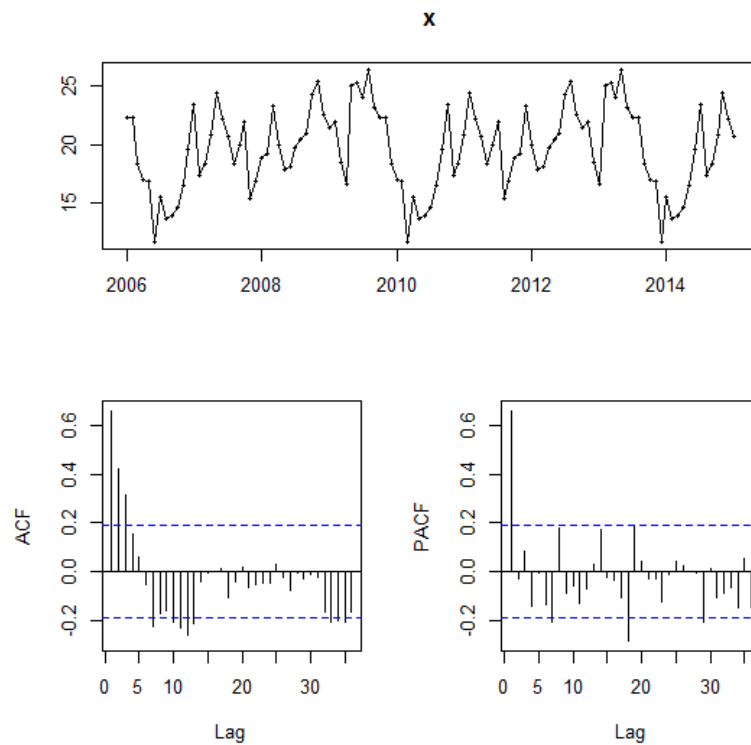
4.1 Análise dos Dados

A partir dos dados de produção dos campos selecionados na Bacia Potiguar foram calculadas as RAO mensais dos campos selecionados entre os anos de 2006 e 2015 para fins de modelagem. Ao realizar a análise da série temporal da RAO de cada campo, com base na autocorrelação e autocorrelação parcial, observou-se que estes dados não resultam em uma série temporal estacionária. Desta maneira, o modelo proposto se baseia na estimação do modelo ARIMA correspondente para cada campo, para que os gráficos de controle dos resíduos possam ser construídos, a fim de realizar o monitoramento.

Para exemplificar como os resultados foram obtidos, as Figuras 12 e 13 trazem a análise dos campos F e A, respectivamente. Estes campos foram escolhidos para ilustrar a metodologia proposta por se tratarem de dois comportamentos extremos durante o processo de modelagem. O Campo F apresentou dados com comportamento de modelagem mais simples e com resíduos cujos resultados em relação à normalidade apresentaram os melhores resultados. Já o Campo A, necessitou de um modelo mais complexo para que fosse obtido os resíduos adequados à obtenção de resultados satisfatórios. Desta forma, tem-se duas situações diferentes para comparação dos resultados.

Pode-se observar que a razão água-óleo do Campo F apresenta uma maior aleatoriedade em torno de um valor central, conforme é possível verificar na série apresentada na Figura 12. Porém, observar também que a autocorrelação (ACF) sofre uma mudança lenta de direção, sugerindo a não estacionariedade destes dados.

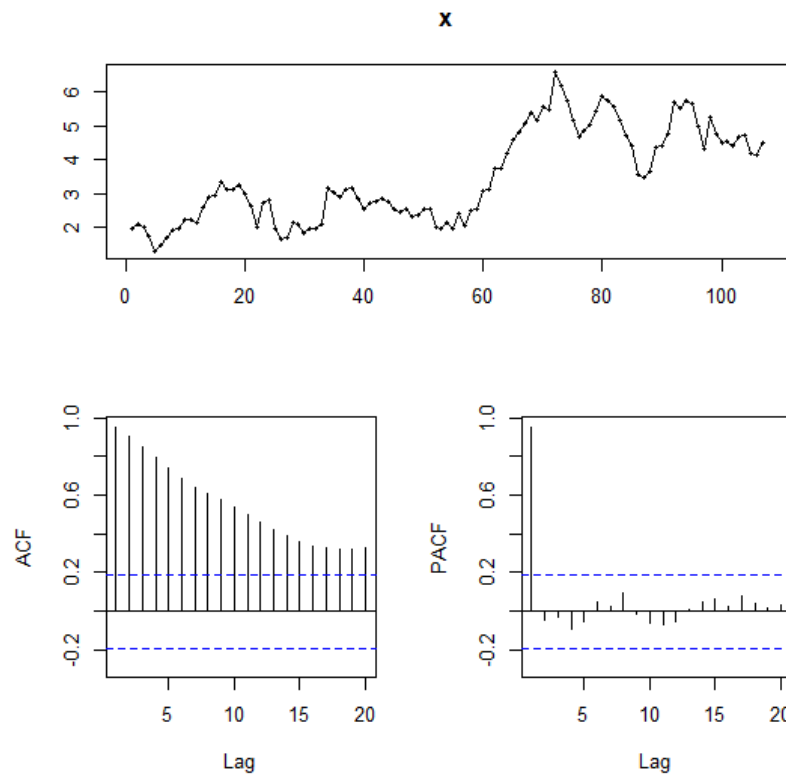
Figura 12 - Análise da razão do campo F no software R



Fonte: elaborada pela autora (2017)

Já a série resultante dos dados do Campo A segue um padrão diferente, pois neste é observado uma tendência ao crescimento da razão com o tempo. Além disso, a análise da autocorrelação aponta um decaimento muito lento. Assim, conclui-se que a série não é estacionária, conforme Figura 13.

Figura 13 - Análise da razão do campo A no software R




Fonte: elaborada pela autora (2017)

Em todos os campos selecionados na pesquisa a análise dos dados da RAO resultou em séries não estacionárias, como pode ser verificado no APÊNDICE B.

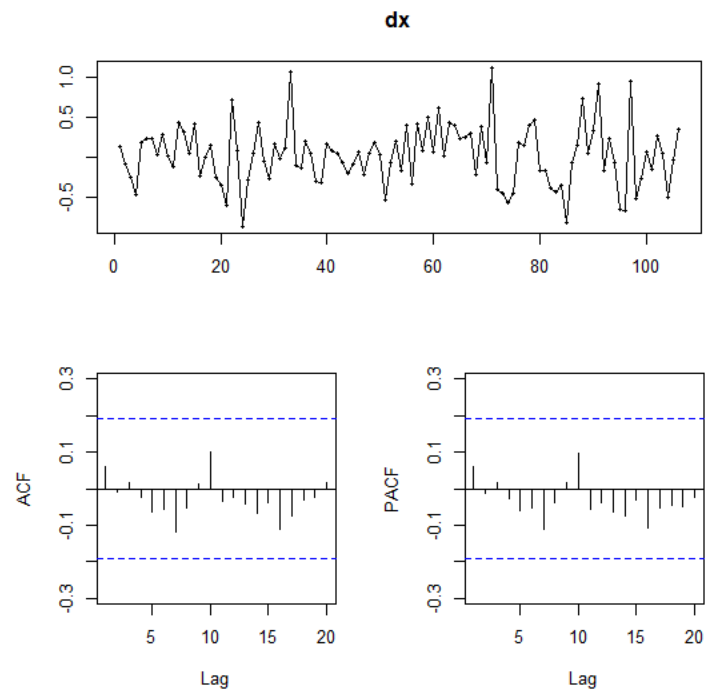
Para tornar as séries estacionárias, foram calculadas, então, as primeiras diferenças desses dados originais e uma nova análise foi realizada a fim de atestar a estacionariedade. As Figuras 14 e 15 apresentam o resultado das séries temporais resultantes dessas transformações para os Campos F e A, respectivamente.

Figura 14 - Análise da Primeira Diferença dos Dados da Razão do Campo F no software R



Fonte: elaborada pela autora (2017)

Figura 15 - Valores da Primeira Diferença dos Dados da Razão do Campo A no software R



Fonte: elaborada pela autora (2017)

A análise dos correlogramas resultantes indicou, portanto, que após o cálculo da primeira diferença as séries resultantes são estacionárias. O mesmo foi feito para todos os campos estudados (ver Apêndice C)

4.2 Ajuste do Modelo Arima

As próximas etapas são a identificação e estimação dos parâmetros do modelo ARIMA para os campos selecionados. Para isto, foram analisados os correlogramas e testadas sucessivas combinações dos parâmetros autorregressivos e de média móvel para determinar o modelo.

O critério utilizado na seleção dos parâmetros adequados se baseou na análise dos resíduos por meio do teste de *Shapiro-Wilk*, que visa medir a normalidade. Assim, foram selecionados os parâmetros cujo modelo resultava em valores p superiores a 0,15 no teste. A Tabela 2 apresenta os modelos ARIMA encontrados para os campos estudados, com os respectivos valores p resultantes do teste de *Shapiro-Wilk* (a 95% de confiança). O p-valor mede, neste caso, a evidência da hipótese de que os resíduos são normais.

A notação utilizada para descrever os modelos está baseada em Morettin e Tolo (2014) que considera que, quando tomadas d diferenças para alcançar a estacionariedade, ficamos com $n = N - d$ observações W_1, \dots, W_n , onde $W_t = \Delta^d Z_t$. Assim, o modelo ARIMA (p, q) resultante poderá ser escrito da seguinte forma:

$$Z_t = \phi_1 Z_{t-1} - \dots - \phi_p Z_{t-p} + a_t + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} \quad (11)$$

Os modelos ARIMA ajustados aos campos estudados estão descritos na Tabela 4.

Tabela 4 - Modelos ARIMA ajustados

6	Modelos ARIMA		P-VALOR
A	(1, 2, 1)	$Z_t = -0,45Z_{t-1} + a_t - a_{t-1}$	0,3178
B	(0, 2, 0)		0,98
C	(2, 1, 0)	$Z_t = -0,68Z_{t-1} - 0,25Z_{t-2} + a_t$	0,4617
D	(4, 1, 0)	$Z_t = -0,87Z_{t-1} - 0,85Z_{t-2} - 0,44Z_{t-3} - 0,28Z_{t-4} + a_t$	0,512
E	(2, 1, 3)	$Z_t = 0,91Z_{t-1} - 0,85Z_{t-2} + a_t - 2,26a_{t-1} + 2,26a_{t-2} - a_{t-3}$	0,5209
F	(1, 0, 1)	$Z_t = -0,53 + a_t - a_{t-1}$	0,9392
G	(4, 3, 0)	$Z_t = -1,78Z_{t-1} - 1,89Z_{t-2} - 1,36Z_{t-3} - 0,56Z_{t-4} + a_t$	0,4713
H	(0, 0, 2)	$Z_t = a_t - 0,44a_{t-1} - 0,21a_{t-2}$	0,7103
I	(2, 0, 1)	$Z_t = -0,35Z_{t-1} - 0,4Z_{t-2} + a_t + 0,18a_{t-1} + 0,04a_{t-2}$	0,4961
J	(0, 1, 2)	$Z_t = a_t - 1,48a_{t-1} + 0,50a_{t-2}$	0,2971
K	(5, 1, 0)	$Z_t = -0,71Z_{t-1} - 0,62Z_{t-2} - 0,40Z_{t-3} - 0,30Z_{t-4} - 0,07Z_{t-5} + a_t$	0,7612
L	(2, 0, 0)	$-0,15Z_{t-1} - 0,33Z_{t-2} + a_t$	0,1741
M	(1, 0, 2)	$Z_t = 0,35Z_{t-1} + a_t - a_{t-1} - 0,20a_{t-2}$	0,1694
N	(2, 0, 3)	$Z_t = 2,18Z_{t-1} - 0,64Z_{t-2} + a_t - 0,86a_{t-1} + 0,86a_{t-2} - a_{t-3}$	0,7106
O	(2, 0, 4)	$Z_t = 0,20Z_{t-1} - 0,64Z_{t-2} + a_t - 0,84a_{t-1} - 0,84a_{t-2} - 0,98a_{t-3} - 0,02a_{t-4}$	0,8133
P	(2, 0, 2)	$Z_t = 0,24Z_{t-1} + 0,23Z_{t-2} + a_t - 0,57a_{t-1} - 0,43a_{t-2}$	0,3225
Q	(3, 0, 1)	$Z_t = 0,24Z_{t-1} + 0,19Z_{t-3} + a_t - 0,57a_{t-1}$	0,7213
R	(1, 0, 1)	$Z_t = -0,86Z_{t-1} + a_t + 0,97a_{t-1}$	0,9514

Fonte: elaborada pela autora (2018)

Os resultados obtidos demonstram que alguns campos resultaram em modelos mais simplificados e com um número pequeno de termos, como por exemplo os campos F e H.

Porém, campos como os campos D e E exigiram modelagens mais complexas e, consequentemente, resultou em um modelo com mais termos autorregressivos e de média móvel.

4.3 Determinação dos Limites de Controle e Simulação

Uma vez os modelos ajustados, foram calculados os limites de controle do gráfico Shewhart e CUSUM para os resíduos de cada um destes a fim de realizar o monitoramento contínuo.


Para elaboração do gráfico de controle Shewhart, foram plotadas as observações individuais do conjunto de dados analisados (resíduos resultantes do modelo ARIMA), a fim de estabelecer os limites. Uma vez estabelecidos os limites, foram plotados os resíduos dos dados referentes ao ano de 2016 para avaliar o estado de controle do processo.

Estes novos dados plotados (os do ano de 2016) foram modelados por meio do mesmo modelo ARIMA ajustado anteriormente ao campo. A partir disso, os resultados dos resíduos foram plotados no gráfico.

Para exemplificar a metodologia adotada e apresentar os resultados preliminares, será exposto o monitoramento dos campos D e R, respectivamente.

O desvio padrão dos resíduos do modelo ARIMA ajustado aos dados do campo D é 1,69 e, o gráfico Shewhart resultante está exposto na Figura 16. Além dos limites, pode-se observar a plotagem dos novos dados, referentes ao ano de 2016, em que se observa a manutenção do controle do processo durante este referido ano.


Figura 16 - Gráfico Shewhart para o ponto D



Fonte: elaborada pela autora (2017)

Para o gráfico CUSUM, foi utilizada a mesma sequência metodológica explicitada anteriormente. Os limites do CUSUM para este campo, seguindo os critérios de $NMA_{m\acute{a}x}$, foram obtidos com um $H = 4\sigma$, obtendo-se os resultados expostos na Figura 17, em que pode ser observada a manutenção do estado de controle para este processo.

Figura 17 - Gráfico CUSUM para o Campo D




Fonte: elaborada pela autora (2017)

Para este campo estudado, podemos observar que não há pontos fora dos limites em nenhum dos gráficos testados, indicando um processo sob controle.


Já os resíduos dos dados relativos ao modelo ARIMA ajustado ao campo R apresentaram um desvio padrão de 0,78. Assim, adotando 2,39 desvios padrão, o gráfico Shewhart resultante está exposto na Figura 18 e os novos dados, referentes ao ano de 2016, permite observar a manutenção do controle do processo. O gráfico de CUSUM para este campo foi determinado considerando $H = 4\sigma$.

Figura 18 - Gráfico Shewhart para o CAMPO R



Fonte: elaborada pela autora (2017)

Figura 19 - Gráfico CUSUM para o Campo R



Fonte: elaborada pela autora (2017)

A Tabela 5 apresenta os resultados dos limites de controle para os campos estudados, salientando que o valor central dos gráficos é zero:

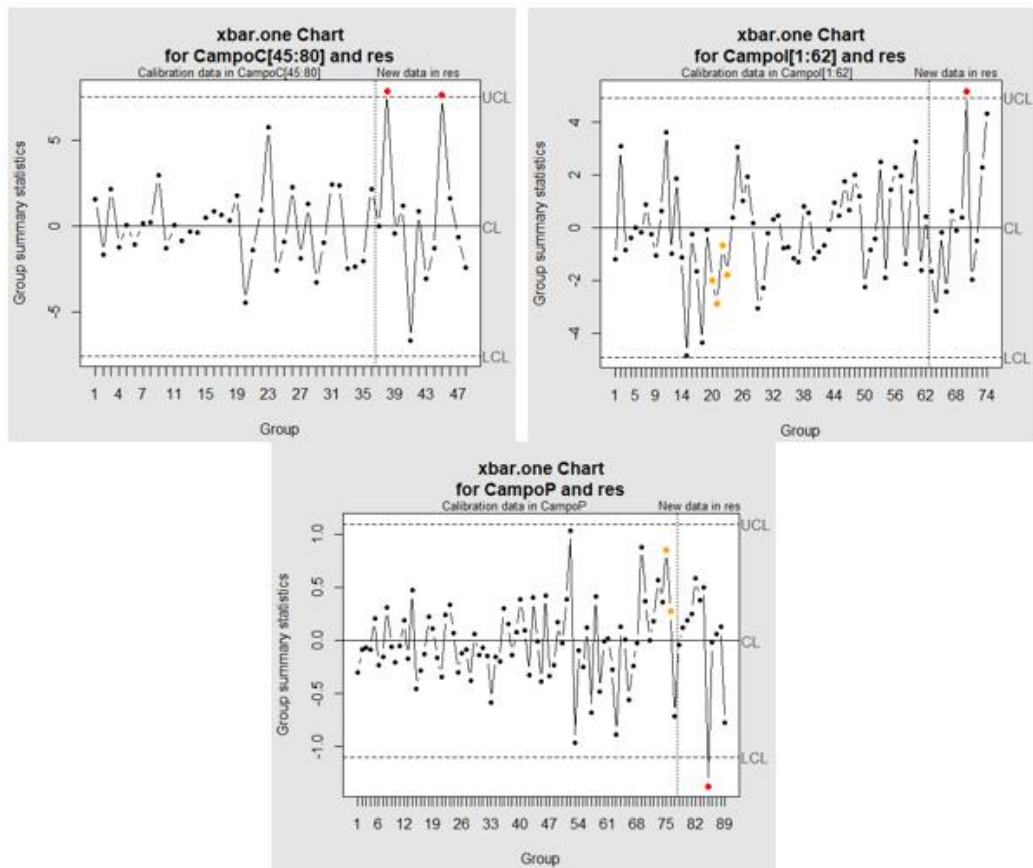
Tabela 5 - Limites de Controle

CAMPO	Shewhart	CUSUM
A	$\pm 1,1036$	$\pm 1,88$
B	$\pm 4,0125$	$\pm 5,35$
C	$\pm 9,3612$	$\pm 15,67$
D	$\pm 4,0375$	$\pm 6,76$
E	$\pm 4,4067$	$\pm 7,38$
F	$\pm 6,1828$	$\pm 10,35$
G	$\pm 0,3320$	$\pm 0,56$
H	$\pm 7,5204$	$\pm 15,68$
I	$\pm 4,9241$	$\pm 8,24$
J	$\pm 1,6624$	$\pm 2,22$
K	$\pm 3,5671$	$\pm 5,12$
L	$\pm 1,4127$	$\pm 2,35$
M	$\pm 1,2109$	$\pm 1,82$
N	$\pm 2,5088$	$\pm 4,73$
O	$\pm 3,1665$	$\pm 5,45$
P	$\pm 1,0975$	$\pm 1,39$
Q	$\pm 6,6558$	$\pm 8,87$
R	$\pm 2,3514$	$\pm 3,14$

Fonte: elaborada pela autora (2018)

Ao serem postados os dados referentes ao ano de 2016, os campos C, I e P apresentaram pontos fora dos limites de controle. Este fato sinaliza que os campos precisam de uma readequação com relação a produção de água e óleo, pois a razão está sendo influenciada por alguma causa especial, conforme pode ser visto na Figura 20.

Figura 20 - Campos com pontos fora dos limites de controle Shewhart

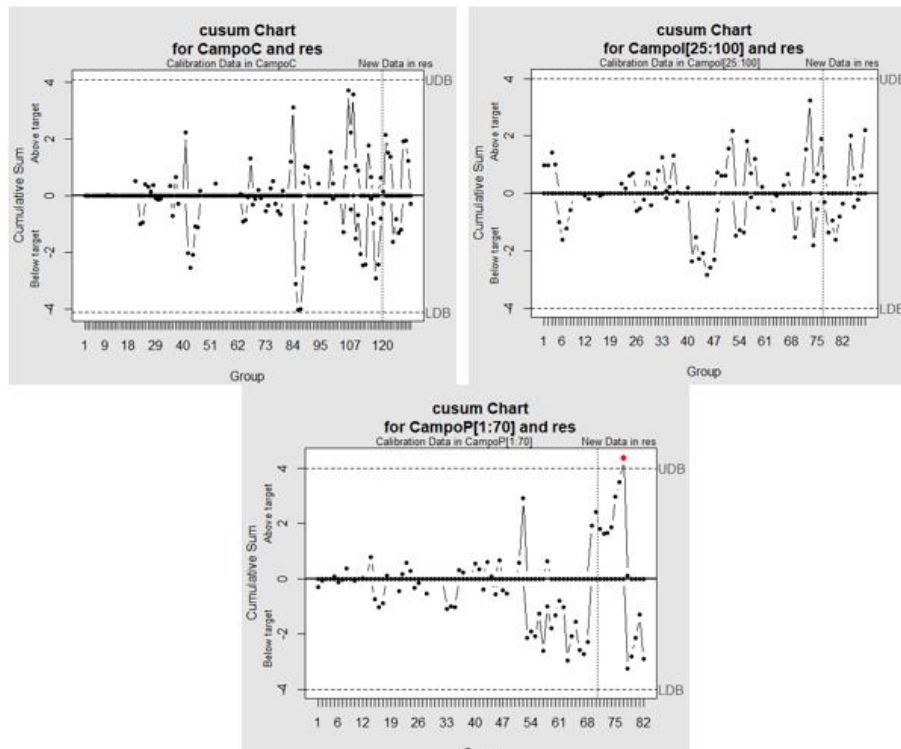


Fonte: elaborada pela autora (2018)

Os pontos em vermelho no gráfico correspondem aos pontos que ultrapassaram os limites de controle.

Considerando os mesmos campos, é possível observar uma diferença de resultados no gráfico CUSUM. O eixo y apresenta os limites em termos do número de desvios padrão. O descontrole dos Campo C e I não foram detectados pelo CUSUM no intervalo de tempo considerado. Já para o Campo P, os dois gráficos detectaram igualmente. A Figura 21:


Figura 21 - Campos com pontos fora dos limites de controle CUSUM



Fonte: elaborada pela autora (2018)

O campo K, apresentou pontos fora dos limites segundo a avaliação por meio do gráfico CUSUM, como pode ser visto na Figura 22:

Figura 22 - Monitoramento do Campo K



Fonte: elaborada pela autora (2018)

4.4 Avaliação do Desempenho dos Gráficos

Após a determinação dos limites, foi realizada uma simulação a fim de avaliar o desempenho destes gráficos com relação a detecção de descontroles. O modelo foi aplicado a dados aleatórios gerados a partir dos parâmetros encontrados para a distribuição de probabilidade destes dados, assim como desvios também foram testados para avaliar qual dos gráficos detecta possíveis descontroles mais rapidamente considerando os limites determinados.

Para a simulação foram gerados até 2.000 números aleatórios e cada um deles foi testado segundo os limites estabelecidos. Ao encontrar um ponto fora dos limites, o algoritmo guarda a informação de qual amostra foi responsável pela sinalização do descontrole. Este experimento foi, então, replicado 5.000 vezes e, ao final, a média do número de amostras até o sinal foi calculada.

Foram avaliadas mudanças da média em termos do número de desvios padrão. Calculou-se o número de amostras até o sinal para $0,1\sigma$, $1,5\sigma$, 2σ e 3σ .

Os resultados podem ser visualizados na Tabela 6:

Tabela 6 - Número de Observações até o sinal

Campo	Shewhart				CUSUM - MÉDIA			
	0,1 σ	1,5 σ	2 σ	3 σ	0,1 σ	1,5 σ	2 σ	3 σ
A	58,89	32,56	2,89	1,38	54,49	20,37	14,89	10,98
B	56,55	32,74	2,85	1,38	50,42	19,6	14,02	10,64
C	58,68	31,4	2,87	1,39	52,45	19,8	14,04	10,86
D	57,32	31,27	2,9	1,37	54,58	19,93	14,05	10,92
E	57,32	32,19	2,87	1,36	52,42	20,03	14,4	10,87
F	58,19	31,12	2,89	1,37	51,14	19,7	14,15	10,59
G	56,88	32,27	2,89	1,37	50,75	19,68	13,92	10,74
H	58,46	31,54	2,85	1,39	51,51	19,98	13,73	10,77
I	57,06	31,21	2,85	1,37	42,01	17,57	13,13	9,88
J	57,35	31,97	2,86	1,38	43,67	18,08	12,9	10,16
K	58,52	31,89	2,9	1,37	50,11	19,65	14,23	10,64
L	57,71	31,88	2,87	1,36	52,89	22,63	16,77	12,81
M	57,85	32,01	2,94	1,37	56,15	22,52	15,87	11,99
N	56,47	31,4	2,85	1,38	53,28	20,23	14,07	10,85
O	57,88	31,2	2,86	1,37	49,49	19,18	13,74	10,39
P	57,26	32,48	2,86	1,37	51,47	19,81	13,55	10,4
Q	57,75	31,31	2,8	1,37	49,88	19,61	13,82	10,65
R	62,28	34,85	3	1,39	50,16	19,33	13,93	10,51
MÉDIA	57,91	31,96	2,88	1,37	50,94	19,87	14,18	10,81

Fonte: elaborada pela autora (2018)

Os resultados demonstram que o gráfico de *Shewhart* é mais eficiente que o CUSUM na detecção de desvios maiores, já o CUSUM detecta mais rapidamente pequenos desvios. Com o resultado da simulação é possível observar que para desvios de 10% e 50%, o diagrama CUSUM demora, respectivamente 50,94 e 19,87 meses para detectar. Enquanto o Shewhart demoraria 57,91 e 31,96 meses. Porém, para desvios de 100% e 200%, o limites de Shewhart consegue detectar mais rapidamente (2,88 e 1,37 meses, respectivamente, *versus* 14,18 e 10,81 do gráfico CUSUM).

5 CONCLUSÕES

Por meio deste estudo, foi possível propor uma metodologia para monitoramento contínuo da medida de Razão Água-Óleo em dezoito campos da Bacia Potiguar e confirmar a tendência natural de aumento contínuo desta razão com o tempo. Além disso, percebe-se uma relação temporal significativa para o comportamento dessa razão, em que poços maduros tendem a produzir um nível elevado de água.

Inicialmente a principal dificuldade encontrada foi o tratamento dos dados, pois estes não estavam plenamente disponíveis para todos os campos. Além disso, foi necessária a determinação de um critério para compor uma amostra mais homogênea, chegando-se então na idade dos campos, fator que está diretamente relacionado com os níveis de razão água-óleo.

Mesmo considerando a idade dos campos na composição da amostra inicial, para alguns deles não foi possível determinar um modelo adequado segundo a metodologia proposta. Desta forma, a amostra final foi determinada.

Como exposto na seção 3, para alguns campos, ainda foi necessário realizar um recorte no conjunto de dados, na busca pela estacionariedade e pela garantia de que os limites seriam estabelecidos com o processo em controle. Considerando-se, então, apenas um subconjunto sequencial desses dados.

Portanto, percebe-se que a etapa de formação da amostra e adequação dos dados para a aplicação da metodologia foi uma etapa extensa e demorada da realização deste trabalho.

Esta metodologia se apresenta, portanto, como uma importante ferramenta para a gestão da água produzida, uma vez que dá subsídios a tomadas de decisão em relação à viabilidade econômica dos campos, uma vez que a água produzida incide apenas em custos para o processo de produção, pois não tem valor comercial e precisa ser tratada para ser reaproveitada ou descartada.

Ademais, é importante ressaltar que os dados não seguem um padrão em relação à modelagem, pois cada campo estudado apresenta um modelo de ajuste diferente. Desta forma, se faz necessário estudar todos eles, modelar individualmente, a fim de determinar limites específicos para cada um. A Tabela 7 apresenta um resumo dos resultados encontrados.

Tabela 7 - Resumo dos Resultados Obtidos

Campo	Quantidade de dados analisados	Modelo ARIMA	Valor-p	Situação (gráfico Shewhart)
A	107	(1, 2, 1)	0,3178	Em controle
B	76	(0, 1, 0)	0,3104	Em controle
C	120	(2, 1, 0)	0,4617	Em controle
D	120	(4, 1, 0)	0,512	Em controle
E	51	(2, 1, 3)	0,5209	Em controle
F	44	(1, 0, 1)	0,9392	Em controle
G	120	(4, 3, 0)	0,4713	Em controle
H	110	(0, 0, 2)	0,7103	Em controle
I	120	(2, 0, 1)	0,4961	Fora de controle
J	69	(0, 1, 2)	0,2971	Em controle
K	79	(0, 1, 0)	0,3974	Em controle
L	59	(2, 0, 0)	0,1741	Em controle
M	35	(1, 0, 2)	0,1694	Em controle
N	120	(2, 0, 3)	0,7106	Em controle
O	120	(2, 0, 4)	0,8133	Fora de controle
P	78	(2, 0, 2)	0,3225	Fora de controle
Q	80	(3, 0, 1)	0,7213	Em controle
R	59	(1, 0, 1)	0,9514	Em controle

Fonte: elaborada pela autora (2018)

De maneira geral, os gráficos para média (*Shewhart*) são eficientes na detecção rápida para desvios grandes. Além disso, esses gráficos são de mais fácil utilização prática. Porém, o gráfico CUSUM se apresenta mais eficiente na detecção de desvios de menor magnitude.

Como recomendação para trabalhos futuros, apresenta-se a necessidade de avaliar o conjunto de dados com outros gráficos de controle, como os limites de múltiplos estágios, por exemplo. Além disso, é necessário avaliar se o modelo ARIMA de fato atende a modelagem desses dados.

Ademais é importante salientar que uma complementação deste trabalho seria incluir os fatores qualitativos à análise atual feita apenas considerando os dados (o uso e influência dos métodos de recuperação no modelo, por exemplo). É recomendado ainda, que se faça

periodicamente (sugestão: dez anos) uma atualização dos modelos e comportamentos dos campos.

REFERÊNCIAS

- ALWAN, L. C.; RADSON, D. Time-series investigation of subsample mean charts. *IIE Transactions*, v. 24, p. 66-80, 1992.
- ALWAN, L. C.; ROBERTS, H. V. Time-Series Modeling for Statistical Process Control. *Journal of Business & Economic Statistics*. v. 6, n. 1, p. 87-95, 1988.
- ANP. Agência Nacional de Petróleo, Gás Natural e Biocombustíveis. Anuário Estatístico Brasileiro do Petróleo e do Gás Natural 2016. Disponível em: <<http://www.anp.gov.br>>. Acesso em: jan. 2017.
- ASSUNÇÃO, C. S. L. T.; VIEIRA, M. M; HO, L. L. Using control chart for a continuous monitoring os the water-oil ratio in fields of the Potiguar Basin / Brazil. *Acta Scientiarum Technology*, In press.
- ATIENZA, O. O., TANG, L. C., AMG, B. W. A SPC procedure for detecting level shifts of autocorrelated processes. *Journal of Quality Technology*. V. 30, P. 340-351, 1998.
- BOX, G. E. P., JENKINS, G. M. Time Series Analysis, forecasting and control. San Francisco: Holden-Day, 1976.
- CENPES. Centro de Pesquisa da Petrobrás. Caracterização do Efluente da Plataforma de Curimã PCR-1. Relatório Técnico Parcial. Disponível em: <<http://www.mma.gov.br/port/conama/processo.cfm?processo=02000.000344/2004-86>>. 2005. Acesso em: maio 2017.
- CLARK, C. E.; VEIL, J. A. Produced water volumes and management practices in the United States. Argonne National Laboratory (ANL), 2009.
- CLARO, F. A. E.; COSTA, A. F. B.; MACHADO, M. A. G. Gráficos de controle de EWMA e de \bar{X} para monitoramento de processos autocorrelacionados. *Revista Produção*. v. 17, n. 3, p. 536-546, 2007.

ELPN/IBAMA. Resolução CONAMA específica sobre o descarte contínuo de Água Produzida em plataformas marítimas de petróleo – Teor de Óleos e Graxas. Nota Técnica nº 001/2006.

ENGLISH, J. R.; LEE, S.-C.; MARTIN, T.W.; TILMON, C. Detecting changes in autoregressive processes with \bar{X} and EWMA charts. IIE Transactions, v. 32, p. 1103-1113, 2000.

FAKHRU'L-RAZIA, A., PENDASHTEHA, A., ABDULLAHA, L. C., BIAKA, D. R. A., MADAENIC, S. S., ABIDINA, Z. Z. Review of technologies for oil and gas produced water treatment. Journal of Hazardous Materials. Volume 170, Pages 530–551, 2009.

GUJARATI, D. N. Econometria Básica, 3. ed., Pearson Education do Brasil. 2006.

HARRIS, K., TRIANTAFYLLOPOULOS, K., STILLMAN, E., MCLEAV, T. A Multivariate Control Chart for Autocorrelated Tool Wear Processes. Quality and Reliability Engineering International. V. 32, P. 2093-2106, 2016.

HUNT, J. M. Petroleum Geochemistry and Geology. 2. ed. New York: H. Freeman: p. 743. 1996.

JIANG, W., TSUI, K., WOODALL, W. H. A new SPC monitoring method: The ARMA chart. Technometrics. V. 42, P. 399-410, 2000.

KOEHLER, A. B.; MARKS, N. B.; O'CONNELL, R. T. EWMA control charts for autoregressive processes. Journal of the Operational Research Society, v. 52, p. 699-707, 2001.

MADDALA, G. S., LAHIRI, K. Introduction to Econometrics. 4a. Edição, John Wiley & Sons Ltd, UK. 2009.

MARIANO, J. B. Impactos ambientais do refino de petróleo. 1 ed. – Rio de Janeiro: Interciência, 2005.

MASTRANGELO, C. M., MONTGOMERY, D. C. SPC with correlated observations for the chemical and process industries. *Quality and Reliability Engineering International*. V. 11, Pages 79-89, 1995.

MONTGOMERY, D. C. *Introduction to Statistical Quality Control*, 4. ed., New York: John Wiley and Sons, 674 p., 2001.

MONTGOMERY, D. C.; MASTRANGELO, C. M. Some statistical process control methods for autocorrelated data. *Journal of Quality Technology*, v. 23, p. 179-193, 1991.

MONTGOMERY, D. C.; RUNGER, G. C. *Estatística aplicada e probabilidade para engenheiros*. 2. ed. Tradução por Verônica Calado. Rio de Janeiro: LTC Editora. 463, 2003.

MORAD, S., WORDEN, R. H., KETZER, J. M. Oxygen and hydrogen isotope composition of diagenetic clay minerals in sandstones: a review of the data and controlling parameters. *Clay Mineral Cement in Sandstones. Int. Assoc. Sediment., Spec. Publ.*, 34: 63–91, 2003.

MORETTIN, P. A.; Toloi, C. M. C. *Análise de Séries Temporais*. 2ª Ed. São Paulo: Blucher, 2006.

NEFF, J., LEE, K., DEBLOIS, M.E., *Produced water: overview of composition, fates, and effects*. Springer, New York Dordrecht Heidelberg London, p. 5. 2011.

OETJEN, K., CHAN, K. E., GULMARK, K., CHRISTENSEN, J. H., BLOTEVOGEL, J., BORCH, T., SPEAR, J. R., CATH, T. Y. Temporal characterization and estatistical analysis of flowback and produced Waters and their potential for reuse. *Science of the total environment*. V. 619-620, p. 654-664. 2018.

OLIVEIRA, A. Petróleo: por que os preços sobem (e descem)? Reportagem. Disponível em: <<http://www.comciencia.br/reportagens/petroleo/pet17.shtml>>. 2002. Acesso em: maio 2017.

OSEI-ANING, R.; ABASI, S. A.; RIAZ, M.. Optimization design of the CUSUM and EWMA charts for autocorrelated processes. *Quality and Reliability Engineering International*. Volume 33, 2017.

PAGE, E. S. Continuous Inspection Schemes. *Biometrika*, v. 41, n. 1, p. 100–115, 1954.

PAN, X., JARRETT, J. Applying state space to SPC: Monitoring multivariate time series. *Journal of Applied Statistics*. V. 31, P. 397-418, 2004.

REYNOLDS, R. R., KIKER, R. D. Produced Water and Associated Issues. A Manual for the Independent Operator. Disponível em: <http://www.pttc.org/pwm/produced_water.pdf>. 2003. Acesso em: Junho/2017

REYNOLDS, M. R. Jr.; LU, C. W. Control charts for monitoring processes with autocorrelated data. *Nonlinear Analysis, Theory, Methods & Applications*, v. 30, p. 4059-4067, 1997.

RUNGER, C. G.; WILLEMAIN, T. R. Model-based and Model-Free control of autocorrelated process. *Journal of Quality Technology*, v. 27, p. 283-292, 1995.

SHAPIRO, S. S., WILK, M. B.. An Analysis of Variance Test for Normality (Complete Samples). *Biometrika Trust*. London, v. 52, p. 591–609, 1965.

SHEWHART, W.A. Economic control of quality of the manufactured product. Van Nostrand, New York. 1931.

STEWART, M., ARNOLD, K. Produced Water Treatment Field Manual. Part 1 - Produced Water Treating Systems, p. 1-134, 2011.

SUPERVILLE, C. R.; ADAMS, B. M. An evaluation of forecast-based quality control schemes. *Communications in Statistics-Simulation and computation*, v. 23, p. 645-661, 1994.

SWAN, J. M., NEFF, J. M., YOUNG, P. C. Environmental Implications of Offshore Oil and Gas Development in Australia – The Findings of an Independent Scientific Review. Australian Petroleum Exploration Association. P.696, 1994.

TESTIK, M. C. Model Inadequacy and Residual Control Charts for autocorrelated processes. *Quality and Reliability Engineering International*, v. 21, p. 115-130. 2004.

THOMAS, J. E. *Fundamentos da Engenharia de Petróleo*. 2 ed., P. 271 – Rio de Janeiro: Interciência, 2001.

UNKEL, S., FARRINGTON, C. P., GARTHWAITE, P. H., ROBERTSON, C., ANDREWS, N. Statistical methods for the prospective detection of infectious disease outbreaks: A review. *Journal of the Royal Statistical Society*, v. 175, p. 49-82, 2012.

URBIETA, P.; HO, L. L.; ALENCAR, A. CUSUM and EWMA Control Charts for Negative Binomial Distribution. *Quality and Reliability Engineering International*. Volume 33, Issue 4, 2017.

VAN BRACKLE, III, L. N., REYNOLDS, M. R. Jr. EWMA and CUSUM control charts in the presence of correlation. *Communication in Statistics - Simulation and computation*, v. 26, p. 979-1008, 1997.

VANDER WIEL, S. A. Monitoring processes that wander using integrated moving average models. *Technometrics*, v. 38, p. 139-151, 1996.

VANHATALO, E., KULAHCI, M. Impact of autocorrelation on principal components and their use in statistical process control. *Quality and Reliability Engineering International*. V. 32, P. 1483-1500, 2016

VEIL, J.V. Research to Improve Water-use Efficiency and Conservation: Technologies and Practice. Argonne National Laboratory. Disponível em: <http://www.ead.anl.gov/pub/doc/testimony_veil_final.pdf>. 2007. Acesso em: Junho/2017.

VIEIRA, V. M. *Modelo de Avaliação do Gerenciamento da Água Produzida em Operações de Produção de petróleo e Gás Natural em Bacias Terrestres Brasileiras*. Tese de Doutorado. UFBA. 2017.

WOODALL, W. H.; MONTGOMERY, D.C. Research issues and ideas in statistical process control. *Journal of Quality Technology*, v. 31, n. 4, p. 376-386, 1999.

WOODALL, W. H. Use of control charts in health care and public health surveillance. *Journal of Quality Technology*, v. 38, p. 88-103, 2006.

ZHANG, N. F. Detection capability of residual control chart for stationary process data. *Journal of Applied Statistics*, v. 24, p. 475-492. 1997.

APÊNDICE A – PROGRAMAS PARA A OBTENÇÃO DOS MODELOS E GRÁFICOS DE CONTROLE

```
#CAMPO A
library(tseries)
library(forecast)
library(qcc)

CampoA <- c(0.505723346, 0.474850963, 0.496555136, 0.567722942, 0.780789888,
0.685489143, 0.588723376, 0.519546843, 0.513334755, 0.448401435, 0.444614055,
0.469092735, 0.388852017, 0.345416799, 0.340694528, 0.298804352, 0.322155862,
0.322718821, 0.308690234, 0.334839321, 0.380527662, 0.495001874, 0.365129005,
0.353620297, 0.514380156, 0.601970916, 0.584937212, 0.468197916, 0.478805861,
0.54964642, 0.505396073, 0.509079042, 0.479350278, 0.316827174, 0.328145112,
0.343063508, 0.321304569, 0.317100202, 0.351487688, 0.395985942, 0.370523401,
0.359355154, 0.353109669, 0.362741435, 0.392374098, 0.405531249, 0.395962851,
0.433539433, 0.426116404, 0.396492622, 0.391749768, 0.496559311, 0.512669589,
0.465090762, 0.503739467, 0.418093736, 0.485944121, 0.402904933, 0.390749388,
0.32745615, 0.321345535, 0.268172973, 0.266942687, 0.23922617, 0.218236447,
0.207527409, 0.197526013, 0.186522888, 0.194318156, 0.18066186, 0.183118496,
0.151729594, 0.161743878, 0.174797605, 0.194476222, 0.213704862, 0.205491036,
0.199500181, 0.184665804, 0.170022302, 0.175003947, 0.180127891, 0.193423445,
0.211197949, 0.228164952, 0.281808427, 0.287491362, 0.275141787, 0.228828875,
0.226379074, 0.210670524, 0.176429711, 0.182040936, 0.17465532, 0.177005678,
0.200674695, 0.232500023, 0.190014192, 0.210646657, 0.223634891, 0.220282959,
0.228269806, 0.215018247, 0.212935428, 0.23865161, 0.240635796, 0.222016083)

CampoARAO <- 1/CampoA      #Cálculo da RAO

dados <- c(4.193692326, 4.127668912, 4.632886645, 5.028935805, 5.111737913,
4.994272773, 5.636200952, 5.814851659, 5.986505203, 5.697737101, 5.35154792,
5.36475402)

plot.ts(CampoARAO)
x <- ts(CampoARAO)
tsdisplay(x)      #Análise da Série Temporal

dCampoA <- diff(CampoARAO)
```

```

dx <- ts(diff(CampoARAO))
tsdisplay(dx)      #Análise da Primeira Diferença

dx.fit <- arima(dx,order=c(1,2,1))    #Ajuste do Modelo ARIMA
summary(dx.fit)
residual<- dx.fit$residual
shapiro.test(dx.fit$residual)

diff(dados)        #Dados de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dados, order=c(1,2,1))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)

CampoAXbar <- dx.fit$residual
qcc(CampoAXbar[25:90], type="xbar.one", std.dev=sd(residual), center=0, newdata=res,
nsigmas=2.39)    #Limites Shewhart

cusum(CampoAXbar, newdata=res, std.dev=sd(residual), center=0, decision.interval = 4)
#Limites CUSUM

# CAMPO B
library(qcc)
library(tseries)
library(forecast)
CampoB <- c(0.085254999, 0.081163416, 0.080201724, 0.080384577, 0.078275546,
0.087973752, 0.084928986, 0.080883567, 0.084303522, 0.082094274, 0.079112421,
0.082312004, 0.09049671, 0.097255566, 0.089436601, 0.089956304, 0.089162106,
0.09030049, 0.089429747, 0.087661899, 0.093206978, 0.096547718, 0.092713549,
0.090017749, 0.089437851, 0.087249668, 0.091899956, 0.090932905, 0.09112274,

```

```
0.076459495, 0.073940174, 0.074843222, 0.071256349, 0.074424185, 0.076224994,
0.07217014, 0.075295113, 0.073619264, 0.074525698, 0.075411281, 0.074805506,
0.074242062, 0.07011463, 0.074740434, 0.073275925, 0.073484811, 0.069419358,
0.072600635, 0.070995526, 0.068989546, 0.071270705, 0.068842864, 0.065865116,
0.066564595, 0.065360629, 0.06301802, 0.062067386, 0.061081456, 0.060767165,
0.058863546, 0.057975875, 0.056678823, 0.055413859, 0.054236522, 0.051220424,
0.050353574, 0.050368623, 0.049408366, 0.048671286, 0.047653657, 0.048191164,
0.047327375, 0.046753192, 0.045991503, 0.046109346, 0.046086995, 0.045822609)
```

```
CampoBRAO <- 1/CampoB    #Cálculo da RAO
```

```
dados <- c(21.98710249, 22.54682584, 22.82256085, 23.48958338, 23.30153831,
23.2001483, 23.73407198, 24.15763536, 24.21110552, 24.80347247, 25.3044886,
24.99007066)
```

```
x <- ts(CampoBRAO, frequency=12,start=c(2006), end=c(2015))
```

```
tsdisplay(x)    #Análise da Série Temporal
```

```
dx <- ts(diff(CampoBRAO))
```

```
tsdisplay(dx)    #Análise da Primeira Diferença
```

```
dx.fit <- arima(dx,order=c(0,2,0))    #Ajuste do Modelo ARIMA
```

```
summary(dx.fit)
```

```
residual<-dx.fit$residual
```

```
shapiro.test(dx.fit$residual)
```

```
diff(dados)    #Dados de 2016
```

```
dxd <- ts(diff(dados))
```

```
plot.ts(dxd)
```

```
tsdisplay(dxd)
```

```
modelo.dados <- arima(dxd, order=c(0,1,0))
```

```
summary(modelo.dados)
```

```
shapiro.test(modelo.dados$residual)
```

```
res <- c(modelo.dados$residual)
```

```
CampoBXbar <- dx.fit$residual
```

```
qcc(CampoBXbar, type="xbar.one", std.dev=sd(residual), center=0, newdata=res,
nsigmais=2.39) #Limites Shewhart
```

```
cusum(CampoBXbar, newdata=res, decision.interval=4, std.dev=sd(residual)) #Limites
CUSUM
```

```
#CAMPO C
```

```
library(tseries)
```

```
library(forecast)
```

```
library(qcc)
```

```
CampoC <- c(0.121060088, 0.111891109, 0.10295271, 0.082050715, 0.111669586,
0.126301559, 0.127877385, 0.081689656, 0.0941043, 0.089653031, 0.070995935,
0.077690936, 0.065603095, 0.077208033, 0.083193162, 0.072353437, 0.063639634,
0.069714543, 0.077548446, 0.096381034, 0.092396363, 0.09736075, 0.115373686,
0.074164286, 0.046194524, 0.070149119, 0.07980391, 0.105032548, 0.112495795,
0.096234661, 0.089579404, 0.097106331, 0.104010177, 0.106591811, 0.084925198,
0.082455309, 0.085785923, 0.100075616, 0.113052476, 0.070474049, 0.077924658,
0.074952339, 0.076311158, 0.075647048, 0.130500728, 0.09240923, 0.051353281,
0.053288028, 0.034447273, 0.036128926, 0.030646127, 0.03295089, 0.034861241,
0.037045708, 0.03089246, 0.032482809, 0.035753357, 0.049643739, 0.061829145,
0.069247345)
```

```
CampoCRAO <- 1/CampoC #Calculo da RAO
```

```
dados <- c(9.084315278, 17.73805656, 16.1178517, 14.24190411, 8.55735463, 11.23226552,
9.890291673, 7.809433018, 16.39304594, 17.20614698, 13.0580194, 11.10318149)
```

```
x <- ts(CampoCRAO, frequency=12, start=c(2006), end=c(2015))
```

```
tsdisplay(x) #Análise da série temporal
```

```
dx <- ts(diff(CampoCRAO))
```

```
plot.ts(dx)
```

```
tsdisplay(dx) #Análise da primeira diferença
```

```
dx.fit <- arima(dx, order=c(2,1,0)) #Ajuste do Modelo ARIMA
```

```
summary(dx.fit)
```

```
residual<-dx.fit$residual
shapiro.test(dx.fit$residual)
```

```
diff(dados)      #Dados de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dados, order=c(2,1,0))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)
```

```
CampoCXbar <- dx.fit$residual
qcc(CampoCXbar, type="xbar.one", center=0, std.dev=sd(residual), newdata=res,
nsigmas=2.39)  #Limites de controle Shewhart

cusum(CampoCXbar, newdata=res, center=0, decision.interval=4, std.dev=sd(residual))
#Limites de controle CUSUM
```

```
#CAMPO D
```

```
library(tseries)
library(forecast)
library(qcc)
```

```
CampoD <- c(0.131812239, 0.128678044, 0.113775382, 0.123239412, 0.095162683,
0.095506182, 0.103690768, 0.067963601, 0.094619751, 0.092674207, 0.084225312,
0.086315491, 0.097559267, 0.095519424, 0.085440139, 0.108056597, 0.11358559,
0.113237775, 0.106885338, 0.116238959, 0.118789307, 0.104083627, 0.118464392,
0.137603128, 0.098862241, 0.094330286, 0.080476721, 0.074344647, 0.090635448,
0.09507903, 0.098837426, 0.105251462, 0.106252992, 0.104340492, 0.109798924,
0.126425372, 0.132254872, 0.14669774, 0.164749248, 0.151940053, 0.145696948,
0.155819358, 0.146573114, 0.174012579, 0.198679742, 0.127478176, 0.121194747,
0.10988493, 0.120195817, 0.117405482, 0.128891062, 0.147710398, 0.151299752,
0.137132852, 0.139678127, 0.153532057, 0.164838119, 0.18974969, 0.218286775,
```

```
0.224502476, 0.25992421, 0.266570417, 0.203824874, 0.293397541, 0.176364376,
0.207305957, 0.208150615, 0.221037161, 0.195161505, 0.221567143, 0.226159844,
0.190688785, 0.193151304, 0.176365431, 0.145563093, 0.127276506, 0.123761756,
0.135070824, 0.121486084, 0.081218983, 0.099885389, 0.20500094, 0.233580421,
0.200176578, 0.213631103, 0.226103264, 0.20283121, 0.188298671, 0.164667032,
0.147949065, 0.111762541, 0.088982692, 0.072620855, 0.082157768, 0.089759445,
0.10015205, 0.122296059, 0.140425327, 0.11594567, 0.103127003, 0.150562711,
0.092633634, 0.072254332, 0.080260411, 0.083960534, 0.075930742, 0.058350718,
0.057184325, 0.066917674, 0.062161406, 0.069656363, 0.071401732, 0.061831768,
0.076784341, 0.066704654, 0.061350408, 0.07025596, 0.072126571, 0.092776934,
0.084665286)
```

```
CampoDRAO <- 1/CampoD #Cálculo da RAO
```

```
dados <- c(11.33629345, 12.11440343, 12.5426067, 12.3015437, 13.07487748, 11.82434345,
11.70591675, 12.50163627, 12.85084024, 12.78864456, 12.70031413, 15.5604242)
```

```
x <- ts(CampoDRAO, frequency=12,start=c(2006), end=c(2015))
```

```
tsdisplay(x) #Análise da Série Temporal
```

```
dx <- ts(diff(FazendaCurralRAO))
```

```
tsdisplay(dx) #Análise da Primeira Diferença
```

```
dx.fit <- arima(dx,order=c(4,1,0)) #Ajuste do modelo ARIMA
```

```
summary(dx.fit)
```

```
residual <- dx.fit$residual
```

```
shapiro.test(dx.fit$residual)
```

```
diff(dados) #Dados de 2016
```

```
dxd <- ts(diff(dados))
```

```
plot.ts(dxd)
```

```
tsdisplay(dxd)
```

```
modelo.dados <- arima(dados, order=c(4,1,0))
```

```
summary(modelo.dados)
```

```
shapiro.test(modelo.dados$residual)
```

```
res <- c(modelo.dados$residual)
```

```

CampoDXbar <- dx.fit$residual
qcc(CampoDXbar[9:75], type="xbar.one", std.dev=sd(residual), center=0, newdata=res,
nsigmas=2.39) #Limites de controle Shewhart

cusum(CampoDXbar, newdata=res, decision.interval = 4, center = 0, std.dev=sd(residual))
#Limites de controle CUSUM

#CAMPO E
library(tseries)
library(forecast)
library(qcc)
CampoE <- c(0.083941093, 0.082524771, 0.07476198, 0.073175862, 0.078936978,
0.075158858, 0.070972772, 0.061646018, 0.058701471, 0.060109402, 0.051869352,
0.052944481, 0.046905694, 0.050074513, 0.056602843, 0.046898739, 0.040766629,
0.041209487, 0.044854568, 0.048241598, 0.050270235, 0.046719694, 0.040914319,
0.045174347, 0.047442257, 0.050614226, 0.050666025, 0.038565144, 0.038865904,
0.041929132, 0.042681039, 0.038320979, 0.039371302, 0.032029589, 0.034827395,
0.035845169, 0.036702593, 0.036712154, 0.038961447, 0.034696496, 0.039232795,
0.039854398, 0.041647661, 0.038226011, 0.041657276, 0.044807395, 0.039403999,
0.034205712, 0.036577052, 0.037824618, 0.032125802, 0.030487969)
CampoERA0 <- 1/CampoE #Cálculo da RAO
x <- ts(CampoERA0, frequency=12,start=c(2006), end=c(2015))
tsdisplay(x) #Análise da série temporal

dados <- c(34.3192796, 36.52006807, 34.37872344, 33.49361597, 28.97951032,
26.42287217, 26.27465922, 26.15785658, 25.96322625, 27.35517511, 27.46896548,
26.35579693)

dx <- ts(diff(CampoERA0))
tsdisplay(dx) #Análise da primeira diferença

dx.fit <- arima(dx,order=c(2,1,3)) #Ajuste do Modelo ARIMA
summary(dx.fit)

```

```
residual<-dx.fit$residual
shapiro.test(dx.fit$residual)
```

```
diff(dados)      #Dados de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dxd, order=c(2,1,3))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)
```

```
CampoEXbar <- dx.fit$residual
qcc(CampoEXbar, type="xbar.one", center=0, std.dev=sd(residual), newdata=res,
nsigmas=2.39)    #Limites de Controle Shewhart

cusum(CampoEXbar, newdata=res, center=0, std.dev=sd(residual), decision.interval=4)
#Limites de Controle CUSUM
```

```
#CAMPO F
```

```
library(tseries)
library(forecast)
library(qcc)
```

```
CampoF <- c(0.044949784, 0.04488603, 0.054457909, 0.058691711, 0.059481152,
0.085990229, 0.064626211, 0.073188352, 0.071734643, 0.068233093, 0.06078705,
0.051216527, 0.042709547, 0.05758752, 0.05458002, 0.047999843, 0.040998534,
0.044970785, 0.048327731, 0.054661323, 0.050033653, 0.04564307, 0.06512532,
0.059199092, 0.053106211, 0.052117753, 0.042968327, 0.049980168, 0.055986187,
0.055317798, 0.050742979, 0.048768789, 0.047678398, 0.04109908, 0.039340136,
0.044459128, 0.046603646, 0.045613798, 0.054032238, 0.060206434, 0.039955094,
0.039597878, 0.041626663, 0.037848501, 0.043106849)
```

```
CampoFRAO <- 1/Campof    #Cálculo da RAO
```



```
dados <- c(15.46159642, 11.48706756, 15.96123461, 16.26900796, 13.17974875,
12.79193081, 13.53531884, 12.726896, 12.05849446, 12.86816364, 15.53602007,
16.09316846) #Dados2016
```

```
x <- ts(CampoFRAO, frequency=12,start=c(2006), end=c(2015))
tsdisplay(x) #Análise da série temporal
```

```
dx <- ts(diff(CampoFRAO))
tsdisplay(dx) #Análise da primeira diferença
```

```
dx.fit <- arima(dx,order=c(1,0,1)) #Ajuste do Modelo ARIMA
summary(dx.fit)
residual <- dx.fit$residual
shapiro.test(dx.fit$residual)
```

```
diff(dados) #Dados de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dados, order=c(1,0,1))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)
```

```
CampoFXbar <- dx.fit$residual
qcc(CampoFXbar, type="xbar.one", std.dev=sd(residual), center=0, newdata=res,
nsigmas=2.39)
```

```
cusum(CampoFXbar, center=0, newdata=res, decision.interval = 4, std.dev=sd(residual))
```

```
#CAMPO G
library(tseries)
library(forecast)
```

```
library(qcc)
```

```
CampoG <- c(2.854096692, 2.942887753, 2.846071124, 3.187807538, 2.92699578,
4.152390144, 5.090530644, 4.157266122, 4.358814632, 3.776989608, 5.272656317,
6.218348484, 4.570370562, 3.787406484, 3.573100819, 3.510967203, 2.831980534,
3.569435098, 3.590039412, 4.251211884, 3.769450775, 2.769747418, 2.490674495,
2.483348238, 2.215807091, 2.671131483, 2.593901286, 2.051701319, 2.229070676,
1.645654154, 1.57965163, 1.97861665, 2.215515059, 2.041173887, 1.934423248,
2.19389647, 2.639854227, 2.765075484, 3.014417375, 2.79834961, 3.542788605,
3.102221529, 2.571845938, 3.18502724, 3.615276551, 2.344142138, 2.156652881,
3.04088595, 4.307555039, 4.01110204, 4.475144463, 5.278779222, 4.776725484,
4.199370914, 3.932179601, 3.414282144, 3.326717706, 2.902898758, 2.94137012,
2.594580668, 3.240795282, 3.688271864, 2.738059618, 4.948456376, 2.547614556,
2.29695184, 1.950828698, 2.388439621, 2.183960009, 2.169452762, 2.312426601,
2.538429808, 2.763637823, 2.658994362, 2.780153769, 2.610800116, 2.148343855,
1.464466717, 1.870909561, 1.893256007, 1.800442304, 2.324238297, 3.610826543,
3.768047279, 1.864990968, 2.060817177, 2.446298276, 2.539449644, 2.898762269,
2.98414069, 3.067475593, 2.992544147, 3.639127854, 3.185814088, 2.210296874,
1.895829128, 2.440006188, 2.162499245, 1.996509984, 2.031586226, 2.09209514,
2.441172473, 2.429474502, 2.22398313, 1.887413935, 1.82877739, 1.585882665,
1.561813236, 1.426074844, 1.502421185, 1.595934241, 1.708209003, 1.623676184,
1.423624277, 1.407687122, 1.242848691, 1.02122061, 1.144041472, 0.917314105,
1.015594034)
```

```
CampoGRAO <- 1/CampoG      #Cálculo da RAO
```

```
dados <- c(0.927542763, 0.982134081, 1.059299971, 1.011788091, 1.111749159,
1.17224688, 0.998411578, 1.011833778, 0.971348304, 0.972221476, 1.056900225,
1.003802989)
```

```
x<-ts(CampoGRAO, frequency=12,start=c(2006), end=c(2015))
```

```
plot.ts(CampoGRAO)
```

```
tsdisplay(x)      #Análise da série temporal
```

```
dx <- ts(diff(LorenaRAO))
```

```
tsdisplay(dx)      #Análise da primeira diferença
```

```
dx.fit <- arima(dx,order=c(4,3,0))      #Ajuste do modelo ARIMA
```

```
summary(dx.fit)
residual<-dx.fit$residual
shapiro.test(dx.fit$residual)
```

```
diff(dados)    #Datos de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dxd, order=c(4,3,0))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)
```

```
CampoGXbar <- dx.fit$residual
qcc(CampoGXbar[1:75], type="xbar.one", std.dev=sd(residual), newdata=res, nsigmas=2.39)

cusum(CampoGXbar, center=0, newdata=res, std.dev=sd(residual), decision.interval=4)
```

```
#CAMPO H
```

```
library(tseries)
library(forecast)
library(qcc)
```

```
CampoH <- c(0.047212023, 0.041392877, 0.054560812, 0.048614489, 0.058981176,
0.046118323, 0.037782131, 0.046211972, 0.053423765, 0.044892985, 0.059874729,
0.056343467, 0.048614529, 0.040573546, 0.03712324, 0.03635258, 0.037242791,
0.039004065, 0.0381438, 0.043770763, 0.035817392, 0.042845589, 0.037856614,
0.039771032, 0.04484051, 0.04769662, 0.044054107, 0.0376598, 0.03581058, 0.033944287,
0.046449436, 0.042210109, 0.048970243, 0.037186802, 0.04239671, 0.049687898,
0.043680208, 0.047345279, 0.05557456, 0.054930876, 0.049987608, 0.049874488,
0.041120954, 0.037486656, 0.040179743, 0.042190995, 0.044798864, 0.046163735,
0.054071708, 0.049248309, 0.036487253, 0.037539408, 0.05020993, 0.037214049,
0.042634905, 0.038327738, 0.030947114, 0.03834063, 0.039358591, 0.038128668,
0.03109331, 0.034784101, 0.034898633, 0.030972267, 0.035201403, 0.034189522,
```

```
0.040009644, 0.043613416, 0.044979209, 0.042655727, 0.036682446, 0.041248522,
0.037016022, 0.03846704, 0.038040621, 0.047335698, 0.040937214, 0.040603067,
0.046934915, 0.040559511, 0.048623127, 0.04767497, 0.052266404, 0.048546314,
0.046025671, 0.04586547, 0.041652677, 0.041342888, 0.037025995, 0.033875107,
0.034430184, 0.03689774, 0.027688703, 0.029338694, 0.035384899, 0.034148203,
0.032960575, 0.03371128, 0.032373788, 0.033054421, 0.04260109, 0.037199233,
0.030080715, 0.03433207, 0.03293411, 0.033220023, 0.036726038, 0.040425287,
0.038816508, 0.03467994, 0.033400033)
```

```
CampoHRAO <- 1/CampoH      #Cálculo da RAO
```

```
dados <- c(32.59123028, 34.67613629, 36.00365184, 37.33530125, 35.40415522,
32.62554177, 32.25946672, 31.06411003, 27.0271593, 28.47722036, 31.23639976,
32.99969656)  #Dados de 2016
```

```
x<-ts(CampoHRAO, frequency=12,start=c(2006), end=c(2015))
```

```
tsdisplay(x)      #Análise da série temporal
```

```
dx <- ts(diff(CampoHRAO))
```

```
tsdisplay(dx)      #Análise da primeira diferença
```

```
dx.fit <- arima(dx,order=c(0,1,1))  #Ajuste do modelo ARIMA
```

```
summary(dx.fit)
```

```
residual<-dx.fit$residual
```

```
shapiro.test(dx.fit$residual)
```

```
diff(dados)      #Dados de 2016
```

```
dxd <- ts(diff(dados))
```

```
plot.ts(dxd)
```

```
tsdisplay(dxd)
```

```
modelo.dados <- arima(dxd, order=c(0,1,1))
```

```
summary(modelo.dados)
```

```
shapiro.test(modelo.dados$residual)
```

```
res <- c(modelo.dados$residual)
```

```
CampoHXbar <- dx.fit$residual
```

```
qcc(CampoHXbar, type="xbar.one", newdata=res, center=0, std.dev=(residual),
nsigmas=2.39)
```

```
cusum(CampoHXbar, newdata=res, center=0, std.dev=(residual), decision.interval=4)
```

```
#CAMPO I
```

```
library(tseries)
```

```
library(forecast)
```

```
library(qcc)
```

```
CampoI <- c(0.218173, 0.25148277, 0.297691552, 0.348406194, 0.307236366, 0.258329607,
0.245715486, 0.260001457, 0.228272663, 0.208331209, 0.190053164, 0.141832059,
0.109547417, 0.114996041, 0.138041234, 0.14044318, 0.167657872, 0.14228582,
0.116284058, 0.114139961, 0.128997164, 0.08695649, 0.093370076, 0.104708075,
0.093986781, 0.091053548, 0.084739935, 0.084941554, 0.092071037, 0.082581577,
0.06160782, 0.068974999, 0.063509811, 0.064042183, 0.094057376, 0.084953713,
0.083443966, 0.136507485, 0.117681169, 0.121382468, 0.193843006, 0.178440566,
0.193889394, 0.175137549, 0.107573224, 0.101149293, 0.091089576, 0.08803356,
0.121028628, 0.14656716, 0.120379977, 0.110185255, 0.107897527, 0.115150134,
0.118678946, 0.126306255, 0.139679168, 0.115529196, 0.104365755, 0.122953186,
0.13095335, 0.125360791, 0.120097329, 0.105153711, 0.099387417, 0.08520094,
0.080592307, 0.070674326, 0.065253487, 0.078692403, 0.080592796, 0.074861142,
0.062283171, 0.072413551, 0.065895736, 0.053988123, 0.050683903, 0.057062403,
0.05145436, 0.042456654, 0.047883711, 0.047810923, 0.043175463, 0.04092073,
0.055511611, 0.050308041, 0.050920923, 0.054100377, 0.059748503, 0.057860466,
0.056658573, 0.049379071, 0.04775473, 0.046721507, 0.0405601, 0.037477353,
0.046303012, 0.045894285, 0.044012305, 0.036469247, 0.039252425, 0.037365389,
0.038729458, 0.036584411, 0.03525749, 0.035273959, 0.038015237, 0.036882551,
0.035172535, 0.033506131, 0.0317654, 0.032550643, 0.037599371, 0.034378863,
0.032690882, 0.029504863, 0.026365679, 0.0313916, 0.029701541, 0.025302142)
```

```
CampoIRAO <- 1/CampoI      #Cálculo da RAO
```

```
dados <- c(36.28224093, 33.18544204, 33.57161228, 32.65532749, 33.82943662,
35.8742987, 36.74969125, 43.26347826, 42.54808767, 39.45724475, 42.5873414,
47.20958807)      #Dados de 2016
```

```
x<-ts(CampoIRAO[20:120], frequency=12,start=c(2006), end=c(2015))
tsdisplay(x)      #Análise da série temporal
```

```
dx <- ts(diff(CampoIRAO[20:120]))
tsdisplay(dx)      #Análise da primeira diferença
```

```
dx.fit <- arima(dx,order=c(2,0,1))      #Ajuste do Modelo ARIMA
summary(dx.fit)
residual<- dx.fit$residual
shapiro.test(dx.fit$residual)
```

```
diff(dados)      #Dados de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dados, order=c(2,0,1))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)
```

```
CampoIXbar <- dx.fit$residual
qcc(CampoIXbar, type="xbar.one", newdata=res, std.dev=sd(residual), center=0,
nsigmas=2.39)      #Limites de controle Shewhart
```

```
cusum(CampoIXbar[51:110], newdata=res, center=0, std.dev=sd(residual),
decision.interval=4)      #Limites de controle CUSUM
```

```
#CAMPO J
```

```
library(tseries)
```

```
library(forecast)
```

```
library(qcc)
```

```
CampoJ <- c(0.188261413, 0.163315114, 0.161440036, 0.149599888, 0.138128131,
0.15988356, 0.152168747, 0.163540404, 0.177098689, 0.165475276, 0.148111261,
```

```
0.171786888, 0.186170919, 0.162984048, 0.146700825, 0.156167659, 0.147298268,
0.133530949, 0.152396386, 0.156984294, 0.152603273, 0.139806395, 0.161109655,
0.163087316, 0.147763748, 0.163379315, 0.174777247, 0.160605286, 0.161311148,
0.161671639, 0.158046694, 0.157667419, 0.142373311, 0.158818355, 0.160705338,
0.1442917, 0.146752655, 0.141366563, 0.163779277, 0.137595498, 0.128652706,
0.135063534, 0.13714521, 0.146561567, 0.127248992, 0.139504232, 0.133128601,
0.125648546, 0.146932522, 0.13341662, 0.132344303, 0.146284912, 0.144314379,
0.131919468, 0.147683032, 0.164397397, 0.196153438, 0.164094256, 0.189214247,
0.179354092, 0.173468499)
```

```
CampoJRAO <- 1/CampoJ #Cálculo da RAO
```

```
dados <- c(3.828693358, 5.331596441, 4.997481512, 5.116149654, 4.784219884,
4.803171085, 4.870212468, 5.007705999, 5.406680039, 7.080940702, 7.911127551,
6.972612703) #Dados de 2016
```

```
x<-ts(CampoJRAO, frequency=12,start=c(2006), end=c(2015))
```

```
tsdisplay(x) #Análise da série temporal
```

```
dx <- ts(diff(CampoJRAO))
```

```
tsdisplay(dx) #Análise da primeira diferença
```

```
dx.fit <- arima(dx,order=c(0,1,2)) #Ajuste do modelo ARIMA
```

```
summary(dx.fit)
```

```
residual<-dx.fit$residual
```

```
shapiro.test(dx.fit$residual)
```

```
diff(dados) #Dados de 2016
```

```
dxd <- ts(diff(dados))
```

```
plot.ts(dxd)
```

```
tsdisplay(dxd)
```

```
modelo.dados <- arima(dados, order=c(0,1,2))
```

```
summary(modelo.dados)
```

```
shapiro.test(modelo.dados$residual)
```

```
res <- c(modelo.dados$residual)
```

```
CampoJXbar <- meu.modelod$residual
```

```

qcc(CampoJXbar, type="xbar.one", center=0, std.dev=sd(residual), newdata=res,
nsigmas=2.39)    #Limites de controle SHewhart

cusum(CampoJXbar, newdata=res, center=0, std.dev=sd(residual), decision.interval=4)
#Limites de controle CUSUM

#CAMPO K
library(tseries)
library(forecast)
library(qcc)
CampoK <- c(0.061102843, 0.060844943, 0.059202736, 0.063775986, 0.058363607,
0.055901217, 0.056303187, 0.055600221, 0.062160245, 0.063249373, 0.064617791,
0.075346708, 0.074077817, 0.073867349, 0.075255838, 0.080562012, 0.084304075,
0.075146159, 0.077188161, 0.076227076, 0.077421204, 0.08228247, 0.085019286,
0.088210777, 0.086301804, 0.08856021, 0.089726602, 0.089995827, 0.080063565,
0.081184202, 0.080581308, 0.080178451, 0.064096056, 0.061126239, 0.064878367,
0.060403244, 0.055513009, 0.051167278, 0.053987238, 0.055877455, 0.056129087,
0.061261563, 0.064052776, 0.064218843, 0.063610112, 0.058340217, 0.064517262,
0.060848533, 0.059663456, 0.056663211, 0.054981454, 0.056414586, 0.053632008,
0.053915693, 0.053208353, 0.051029552, 0.052189134, 0.053692606, 0.053171256,
0.050365265, 0.049510882, 0.046519564, 0.043701759, 0.047144403, 0.050064484,
0.050366044, 0.051600052, 0.04911937, 0.049425764, 0.049890764, 0.050174708,
0.0513174, 0.046251633, 0.044848603, 0.044828603, 0.046280812, 0.04787938,
0.050169123, 0.049221104, 0.046938815)
CampoKRAO <- 1/CampoK    #Cálculo da RAO
dados <- c(21.32978831, 23.25755846, 24.54384074, 26.31357087, 29.41556174,
28.05968684, 29.21616174, 28.62229146, 27.56989329, 28.47115167, 29.19569909,
28.95589499)    #Dados de 2016
x<-ts(CampoKRAO, frequency=12,start=c(2006), end=c(2015))
tsdisplay(x)    #Análise da Série Temporal

dx <- ts(diff(CampoKRAO))    #Análise da primeira diferença
tsdisplay(dx)

```



```
dx.fit <- arima(dx,order=c(0,1,0)) #Ajuste do Modelo ARIMA
summary(dx.fit)
residual <- dx.fit$residual
shapiro.test(dx.fit$residual)
```

```
diff(dados)      #Dados de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dados, order=c(0,1,0))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)
```

```
CampoK <- dx.fit$residual
qcc(CampoKXbar, type="xbar.one", newdata=res, center=0, std.dev=sd(residual),
nsigmas=2.58) #Limites de controle Shewhart

cusum(CampoK, newdata=res, center=0, std.dev=sd(residual), decision.interval=4)
#Limites de controle CUSUM
```

```
#CAMPO L
```

```
library(tseries)
library(forecast)
library(qcc)
```

```
CampoL <- c(0.453618204, 0.490469773, 0.432816365, 0.566092147, 0.441320994,
0.351860123, 0.526859989, 0.535177719, 0.506612461, 0.371545691, 0.434311363,
0.360319104, 0.339895129, 0.431085816, 0.412452281, 0.246085759, 0.417974118,
0.836343094, 0.92125666, 0.910490116, 0.75093084, 0.823055948, 1.111617877,
1.482599917, 1.512912502, 0.936789147, 0.950351685, 0.945745319, 0.783155626,
0.749444483, 1.201536181, 1.525373054, 1.101211956, 1.273252652, 1.295161396,
1.136773986, 1.095214851, 0.659639838, 0.754051754, 0.755196209, 0.612109598,
```

```
0.586780014, 0.51512239, 0.475349579, 0.473000358, 0.382213741, 0.313870586,
0.336291834, 0.34146981, 0.341990508, 0.375583944, 0.31280763, 0.340288645,
0.350811418, 0.294853488, 0.329455557, 0.324237013, 0.344398287, 0.247938369,
0.21653012)
```

```
CampoLRAO <- 1/CampoL      #Cálculo da RAO
```

```
dados <- c(4.924260164, 3.184551673, 3.814947261, 3.759963333, 3.41469704,
2.591567077, 3.322717031, 3.951357382, 2.565536674, 3.571416679, 3.534450411,
3.373639149)      #Dados de 2016
```

```
x<-ts(CampoLRAO, frequency=12,start=c(2006), end=c(2015))
```

```
tsdisplay(x)      #Análise da série temporal
```

```
dx <- ts(diff(PocoVerdeRAO))
```

```
tsdisplay(dx)      #Análise da primeira diferença
```

```
dx.fit <- arima(dx,order=c(2,0,0))      #Ajuste do modelo ARIMA
```

```
summary(dx.fit)
```

```
residual<-dx.fit$residual
```

```
shapiro.test(dx.fit$residual)
```

```
diff(dados)      #Dados de 2016
```

```
dxd <- ts(diff(dados))
```

```
plot.ts(dxd)
```

```
tsdisplay(dxd)
```

```
modelo.dados <- arima(dados, order=c(2,0,0))
```

```
summary(modelo.dados)
```

```
shapiro.test(modelo.dados$residual)
```

```
res <- c(modelo.dados$residual)
```

```
CampoLXbar <- dx.fit$residual
```

```
qcc(CampoLXbar[19:57], type="xbar.one", std.dev=sd(residual), center=0, newdata=res)
```

```
#Limites de controle Shewhart
```

```
cusum(CampoLXbar[26:58], newdata=res, center=0, std.dev=sd(residual),
```

```
decision.interval=4) #Limites de controle CUSUM
```

```

#CAMPO M
library(tseries)
library(forecast)
library(qcc)
CampoM <- c(0.251494257, 0.386844592, 0.339197521, 0.354993477, 0.555512093,
0.624619295, 0.466839731, 0.483104078, 0.383230106, 0.271095565, 0.332344624,
0.355888729, 0.37740556, 0.331561746, 0.389971535, 0.358060869, 0.38981602,
0.311425753, 0.285234715, 0.317690186, 0.297795276, 0.269276259, 0.260134194,
0.289478874, 0.392244704, 0.266274993, 0.294007923, 0.244526271, 0.272261995,
0.537769293, 0.620446909, 0.440955053, 0.397241401, 0.3537364, 0.28804241,
0.260740789, 0.269331162, 0.245403408, 0.284011243, 0.247711176, 0.244623377,
0.240621205, 0.207724396, 0.195225915, 0.227810578, 0.188710217, 0.183718357,
0.165292516, 0.180952364, 0.205151659, 0.140306603, 0.205205787, 0.198081842,
0.199788789, 0.180782578, 0.15940438, 0.192711557, 0.128413823, 0.129150281,
0.17859387, 0.190890545, 0.177771192, 0.113960092, 0.157008819, 0.103597452,
0.083052631, 0.078676858, 0.154005721, 0.088424742, 0.074002673, 0.08977878,
0.120238711, 0.129377164, 0.132690456, 0.171016662, 0.161398164, 0.149738886,
0.131900211, 0.137461418, 0.142214872, 0.272401125, 0.464424674, 0.476276442,
0.463171039, 0.409835, 0.42101267, 0.344528622, 0.311965183, 0.326721364,
0.303668532, 0.263965869, 0.274370504, 0.345309462, 0.326086602, 0.552367826,
0.29398619, 0.280553568, 0.30027803, 0.318815414, 0.41206682, 0.317924046,
0.394911892, 0.359930552, 0.357265897, 0.3382691, 0.338847208, 0.332928875,
0.368413167, 0.350319347, 0.360962968, 0.400352165, 0.477404922, 0.397156117,
0.316371496, 0.322340128, 0.319710438, 0.341822741, 0.340867645, 0.29457359,
0.309057772)

CampoMRAO <- 1/CampoM #Cálculo da RAO
dados <- c(3.024146343, 2.906246369, 2.918087776, 3.018038003, 3.104947337,
2.961310203, 3.587876537, 3.726146, 3.817940216, 3.511199902, 3.773380494,
3.958784503) #Dados de 2016

x<-ts(CampoMRAO)
tsdisplay(x) #Análise da série temporal

```

```

dx <- ts(diff(CampoMRAO[85:120]))
tsdisplay(dx)    #Análise da primeira diferença

dx.fit <- arima(dx,order=c(1,0,2))  #Ajuste do modelo ARIMA
summary(dx.fit)
residual <- dx.fit$residual
shapiro.test(dx.fit$residual)

diff(dados)    #Dados de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dados, order=c(1,0,2))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)

CampoMXbar <- dx.fit$residual
qcc(CampoMXbar, type="xbar.one", center=0, std.dev=sd(residual), newdata=res,
nsigmas=2.39)    #Limites de controle Shewhart

cusum(CampoMXbar, newdata=res, center=0, std.dev=sd(residual), decision.interval=4)
#Limites de controle CUSUM

#CAMPO N
library(tseries)
library(forecast)
library(qcc)
CampoN <- c(0.083588833, 0.076330776, 0.071501637, 0.077762348, 0.161516291,
0.058567839, 0.074735655, 0.086191291, 0.069515705, 0.094101956, 0.109860028,
0.07042889, 0.068085384, 0.064826758, 0.183565721, 0.231479605, 0.144573479,
0.132828829, 0.119497897, 0.126900625, 0.133382954, 0.138988414, 0.114402282,

```

```
0.16005742, 0.108753323, 0.105809075, 0.125118875, 0.235987851, 0.188390039,
0.134534103, 0.172826177, 0.116893853, 0.103424318, 0.107419962, 0.125576572,
0.136038175, 0.093410359, 0.117332945, 0.105435388, 0.121504032, 0.14318952,
0.111308044, 0.106204805, 0.115014936, 0.129635741, 0.133671515, 0.130458822,
0.136571531, 0.123867269, 0.133533637, 0.114326241, 0.166962667, 0.134348132,
0.121576907, 0.132523484, 0.113959988, 0.123872783, 0.123317748, 0.124978275,
0.113672551, 0.09759761, 0.112746482, 0.119238895, 0.114101874, 0.132230641,
0.128113054, 0.148191715, 0.139484938, 0.142082937, 0.10456448, 0.100456346,
0.114101043, 0.10961755, 0.105684117, 0.109030953, 0.107409669, 0.109172663,
0.12259103, 0.111946575, 0.108425269, 0.138360982, 0.134987149, 0.133284149,
0.119051102, 0.112904512, 0.108929721, 0.142715763, 0.125144691, 0.136714456,
0.158282311, 0.145552431, 0.126858494, 0.159214135, 0.144659767, 0.149830416,
0.14461298, 0.138124128, 0.136156102, 0.144015518, 0.13051411, 0.134308637,
0.120610714, 0.103160304, 0.121376487, 0.110319588, 0.123097896, 0.1102456,
0.129011541, 0.124925832, 0.134034887, 0.113657938, 0.185073398, 0.118555607,
0.130153586, 0.13130715, 0.159875626, 0.150937622, 0.145181091, 0.133282488,
0.135345537)
```

```
CampoNRAO <- 1/CampoN      #Cálculo da RAO
```

```
dados <- c(7.658785975, 8.293181319, 8.653618238, 7.212887718, 8.163252291,
8.581645874, 8.196908878, 8.660221608, 8.503966601, 8.907943829, 8.96335289,
8.507545614)      #Dados de 2016
```

```
x<-ts(CampoNRAO, frequency=12,start=c(2006), end=c(2015))
```

```
tsdisplay(x)      #Análise da série temporal
```

```
dx <- ts(diff(CampoNRAO[20:120]))
```

```
tsdisplay(dx)      #Análise da segunda diferença
```

```
dx.fit <- arima(dx,order=c(2,2,3))      #Ajuste do Modelo ARIMA
```

```
summary(dx.fit)
```

```
residual <- dx.fit$residual
```

```
shapiro.test(dx.fit$residual)
```

```
diff(dados)      #Dados de 2016
```

```
dxd <- ts(diff(dados))
```

```

plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dados, order=c(2,2,3))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)

CampoNXbar <- dx.fit$residual
qcc(CampoNXbar, type="xbar.one", center=0, std.dev=sd(residual), newdata=res)

cusum(CampoNXbar, newdata=res, center=0, std.dev=sd(residual), decision.interval=4)

#CAMPO O
library(tseries)
library(forecast)
library(qcc)
CampoO <- c(0.107450444, 0.111156039, 0.123092522, 0.109970341, 0.10174953,
0.10225914, 0.10095179, 0.099100722, 0.104409218, 0.104633766, 0.120324946,
0.095187935, 0.10162803, 0.099826231, 0.099005951, 0.103170662, 0.115599721,
0.120636857, 0.110697043, 0.114057754, 0.107491553, 0.114111583, 0.110657498,
0.103686778, 0.103855691, 0.116104043, 0.115480756, 0.109110363, 0.110218078,
0.097553154, 0.097141833, 0.091596224, 0.07979358, 0.090605901, 0.09479756,
0.084020519, 0.077915283, 0.073433025, 0.080556555, 0.104265462, 0.08270385,
0.079753716, 0.088306867, 0.071366165, 0.068685171, 0.079631291, 0.085952716,
0.093892623, 0.084150678, 0.077503422, 0.079016971, 0.070090129, 0.072909848,
0.070823387, 0.077777383, 0.082438035, 0.077351372, 0.087246669, 0.082895459,
0.074943312, 0.082733731, 0.086308354, 0.089793051, 0.082752265, 0.070947283,
0.062295353, 0.065201311, 0.069453249, 0.063760545, 0.064224153, 0.075159289,
0.061826242, 0.054107113, 0.064793498, 0.057967159, 0.055411834, 0.060791346,
0.057026778, 0.061671677, 0.066677022, 0.062430561, 0.056636124, 0.052539305,
0.061068268, 0.060329674, 0.048964852, 0.054755678, 0.049222337, 0.042041393,
0.045458979, 0.043200347, 0.043820509, 0.046858239, 0.045017542, 0.043682376,
0.035843673, 0.043468825, 0.046444327, 0.046775494, 0.050089798, 0.047222474,

```

```

0.042277024, 0.040843096, 0.040217312, 0.039947544, 0.044778155, 0.04662312,
0.046816581, 0.045578747, 0.048619696, 0.048501013, 0.047639513, 0.055815949,
0.051793829, 0.04451544, 0.048627183, 0.055829777, 0.051029587, 0.048712255,
0.051739491)
CampoORAO <- 1/CampoO      #Cálculo da RAO
dados <- c(20.00818885, 20.40294454, 20.91603122, 21.54845721, 24.00311991,
23.97356626, 23.95694227, 23.24252829, 22.20895361, 27.09628368, 25.28935793,
27.37306563)
x<-ts(CampoORAO, frequency=12,start=c(2006), end=c(2015))
tsdisplay(x)      #Análise da série temporal

dx <- ts(diff(CampoORAO))
tsdisplay(dx)      #Análise da primeira diferença

dx.fit <- arima(dx,order=c(1,1,3))
summary(dx.fit)
residual <- dx.fit$residual
shapiro.test(dx.fit$residual)

diff(dados)      #Dados de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dados, order=c(1,1,3))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)

CampoOXbar <- dx.fit$residual
qcc(CampoOXbar[1:90], type="xbar.one", center=0, std.dev=sd(residual), newdata=res)

cusum(CampoOXbar, newdata=res, decision.interval=4, center=0), std.dev=sd(residual))

```

```

#Campo P
library(tseries)
library(forecast)
library(qcc)

CampoP <- c(0.50967573, 0.597696521, 0.601846003, 0.588534576, 0.588044434,
0.495056669, 0.553037044, 0.580915703, 0.460466459, 0.471698146, 0.520970701,
0.51009606, 0.444667386, 0.476867331, 0.378548896, 0.473849596, 0.530793719,
0.515923388, 0.427640635, 0.397847374, 0.426421189, 0.486107901, 0.404502136,
0.346318462, 0.346082182, 0.397887186, 0.407196743, 0.402310918, 0.45193532,
0.403255504, 0.400518351, 0.390285405, 0.392106836, 0.476237162, 0.446491301,
0.429749243, 0.347986878, 0.320931831, 0.337084213, 0.322627451, 0.283654496,
0.283422363, 0.323065093, 0.280814432, 0.285612064, 0.327469866, 0.277416878,
0.307806402, 0.324749381, 0.292304492, 0.288744638, 0.256020224, 0.204849083,
0.28444661, 0.291525834, 0.299680395, 0.276325364, 0.328606767, 0.268021317,
0.297242938, 0.283102249, 0.267523971, 0.280308554, 0.351178526, 0.294088578,
0.269753867, 0.302642685, 0.296990937, 0.273411997, 0.209932523, 0.199915963,
0.210596408, 0.2088926, 0.19119823, 0.187545879, 0.169754359, 0.175266607,
0.21867557)

CampoPRAO <- 1/CampoP      #Cálculo da RAO

dados <- c(11.89635334, 12.12813141, 12.20061886, 12.10321811, 12.39277474,
12.28111861, 12.25756944, 10.40852968, 11.80454092, 12.92710214, 12.26436523,
10.4143885)      #Dados de 2016

x<-ts(CampoPRAO, frequency=12,start=c(2006), end=c(2015))
tsdisplay(x)      #Análise da série temporal

dx <- ts(diff(CampoPRAO))
tsdisplay(dx)      #Análise da primeira diferença

dx.fit <- arima(dx,order=c(2,0,2))      #Ajuste do Modelo ARIMA
summary(dx.fit)
residual <- dx.fit$residual
shapiro.test(dx.fit$residual)

```



```

diff(dados)      #Dados de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)
modelo.dados <- arima(dados, order=c(2,0,2))
summary(modelo.dados)
shapiro.test(modelo.dados$residual)
res <- c(modelo.dados$residual)

CampoPXbar <- dx.fit$residual
qcc(CampoPXbar, type="xbar.one", center=0, std.dev=sd(residual), newdata=res)
#Limites de controle Shewhart

cusum(CampoPXbar, newdata=res, center=0, std.dev=sd(residual), decision.interval=3.8)
#Limites de controle CUSUM

#CAMPO Q
library(tseries)
library(forecast)
library(qcc)
CampoQ <- c(0.16294824, 0.141638309, 0.131735886, 0.16199781, 0.203780125,
0.138827869, 0.138781096, 0.140072516, 0.134705523, 0.09274315, 0.093094124,
0.127744149, 0.136561766, 0.111578947, 0.105671255, 0.097150595, 0.09268813,
0.100813309, 0.083980221, 0.080417335, 0.083564599, 0.087268879, 0.082682203,
0.079706799, 0.080847278, 0.118612803, 0.064776744, 0.049016788, 0.07559638,
0.059504084, 0.069274566, 0.078186666, 0.06861536, 0.074519872, 0.082959287,
0.091435158, 0.131571112, 0.145327458, 0.128974761, 0.124613072, 0.158525233,
0.140649641, 0.119071582, 0.177893704, 0.201369597, 0.110408499, 0.488095238,
0.131061769, 0.093571327, 0.0783303, 0.090405764, 0.087156524, 0.074705395,
0.083679957, 0.090125388, 0.10475611, 0.11951679, 0.119689045, 0.111317601,
0.092989772, 0.101054144, 0.123613304, 0.11818979, 0.242620139, 0.15528032,
0.215830951, 0.136532851, 0.143943778, 0.18348305, 0.118982234, 0.107089254,

```

```
0.091738557, 0.096565912, 0.116918869, 0.077531158, 0.075005702, 0.066919034,
0.06695686, 0.065420435, 0.05621447, 0.050704167)
```

```
CampoQRAO <- 1/CampoQ      #Cálculo da RAO
```

```
dados <- c(8.527966353, 11.68385692, 12.17417235, 13.67701491, 14.33274917,
15.57869638, 16.89599014, 22.05357722, 26.92997956, 27.42826253, 22.09843927,
25.27818744)      #Dados de 2016
```

```
x<-ts(CampoQRAO, frequency=12,start=c(2006), end=c(2015))
```

```
tsdisplay(x)      #Análise da Série Temporal
```

```
dx <- ts(diff(CampoQRAO))
```

```
tsdisplay(dx)      #Análise da primeira diferença
```

```
dx.fit <- arima(dx,order=c(3,0,1))      #Ajuste do Modelo ARIMA
```

```
summary(dx.fit)
```

```
residual <- dx.fit$residual
```

```
shapiro.test(dx.fit$residual)
```

```
diff(dados)      #Dados de 2016
```

```
dxd <- ts(diff(dados))
```

```
plot.ts(dxd)
```

```
tsdisplay(dxd)
```

```
modelo.dados <- arima(dados, order=c(3,0,1))
```

```
summary(modelo.dados)
```

```
shapiro.test(modelo.dados$residual)
```

```
res <- c(modelo.dados$residual)
```

```
CampoQXbar <- dx.fit$residual
```

```
qcc(CampoQXbar, type="xbar.one", center=0, std.dev=sd(residual), newdata=res)
```

```
cusum(CampoQXbar, newdata=res, center=0, std.dev=sd(residual), decision.interval=4)
```

```
#CAMPO R
```

```

library(tseries)
library(forecast)
library(qcc)
CampoR <- c(0.286283387, 0.322993693, 0.348630349, 0.259708648, 0.278808423,
0.288525835, 0.266555488, 0.197307982, 0.212867101, 0.195248485, 0.211236324,
0.2030601, 0.226645853, 0.205251144, 0.192080916, 0.296715032, 0.354443242,
0.339978664, 0.242328349, 0.310374667, 0.314787905, 0.406470022, 0.437060941,
0.312400404, 0.247723504, 0.173361245, 0.156830576, 0.192679307, 0.230312282,
0.224355092, 0.203751183, 0.207049596, 0.205001359, 0.206603188, 0.238174316,
0.317906631, 0.366443644, 0.246280212, 0.484759335, 0.40478446, 0.359095644,
0.434714645, 0.422801291, 0.455274806, 0.250254407, 0.163961064, 0.183525569,
0.227288504, 0.201486226, 0.180896619, 0.18104491, 0.187921369, 0.184182058,
0.170714614, 0.197252275, 0.19475504, 0.176776502, 0.171245349, 0.15566702,
0.167434917)
CampoRRAO <- 1/CampoR      #Cálculo da RAO
dados <- c(8.786881477, 9.129682426, 8.224736531, 9.729338811, 9.437520991,
7.280083028, 5.703478979, 5.700948341, 5.50171798, 5.615609313, 7.017136386,
7.745578193)

x<-ts(CampoRRAO, frequency=12,start=c(2006), end=c(2015))
tsdisplay(x)      #Análise da Série Temporal

dx <- ts(diff(CampoRRAO))
tsdisplay(dx)      #Análise da primeira diferença

dx.fit <- arima(dx,order=c(1,0,1))      #Ajuste do Modelo ARIMA
summary(dx.fit)
residual <- dx.fit$residual
shapiro.test(dx.fit$residual)

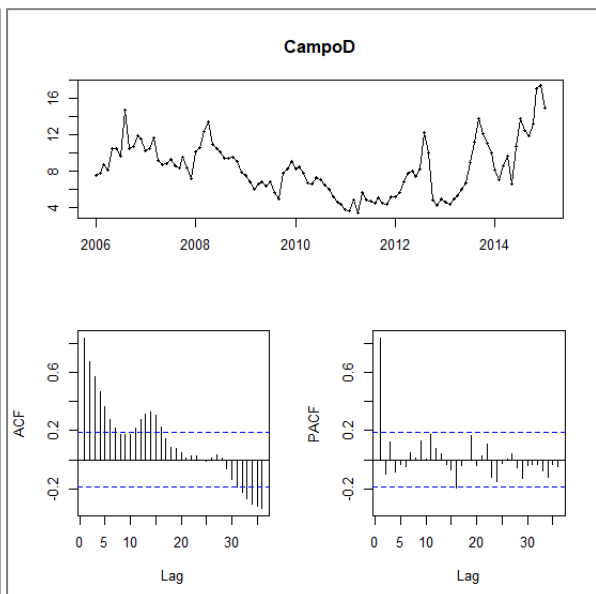
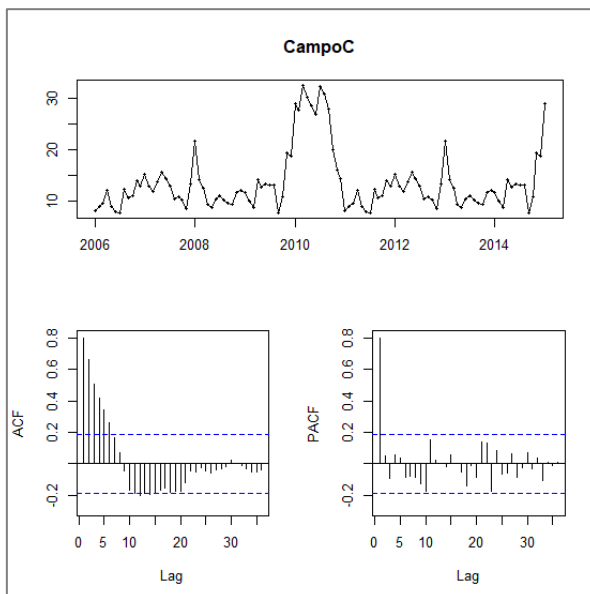


diff(dados)      #Dados de 2016
dxd <- ts(diff(dados))
plot.ts(dxd)
tsdisplay(dxd)


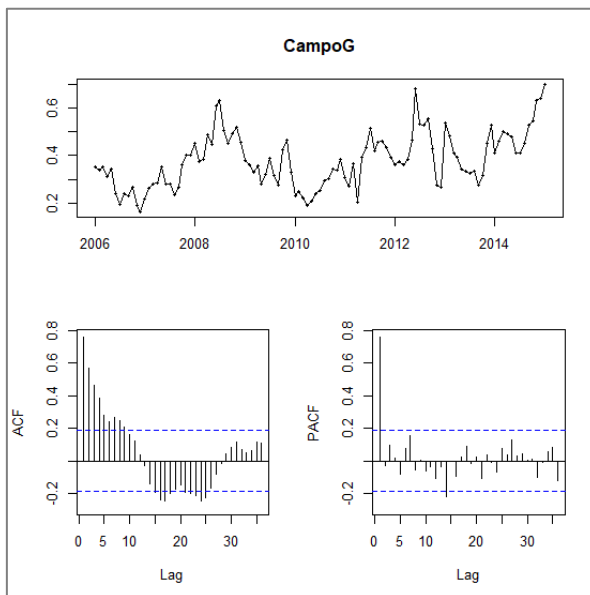

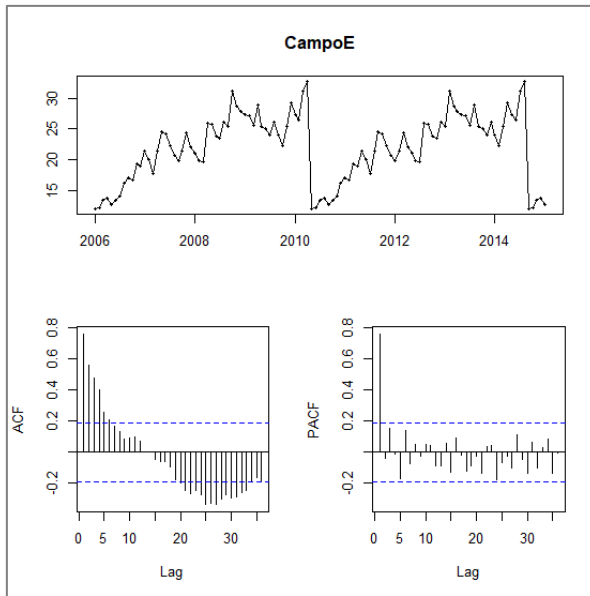
```


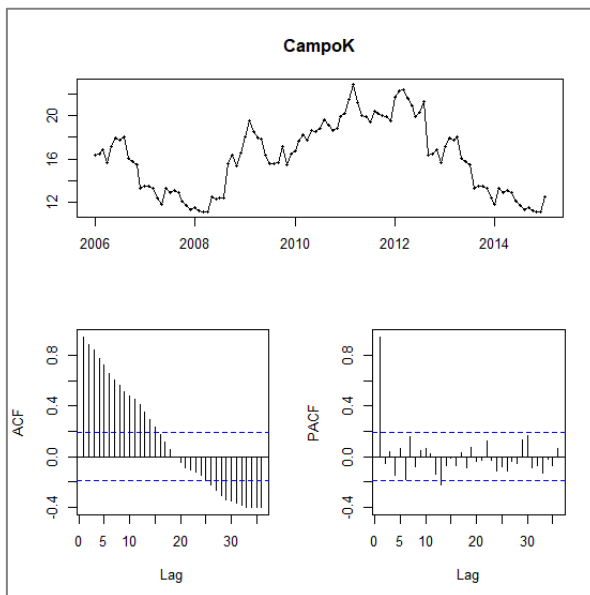

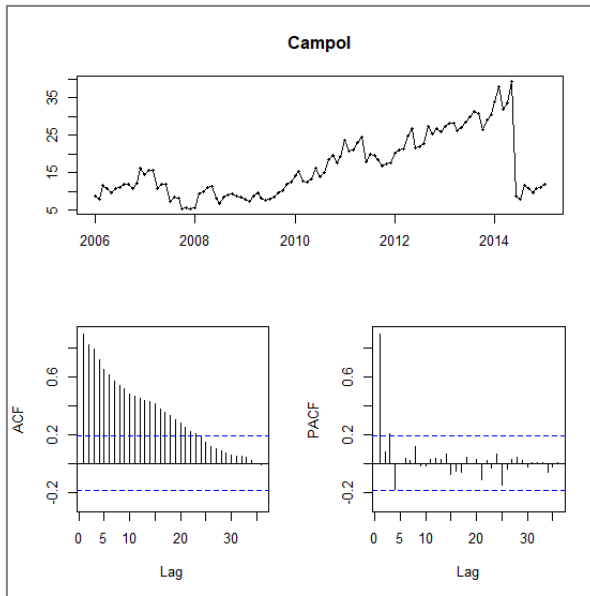
```
modelo.dados <- arima(dados, order=c(1,0,1))  
summary(modelo.dados)  
shapiro.test(modelo.dados$residual)  
res <- c(modelo.dados$residual)
```


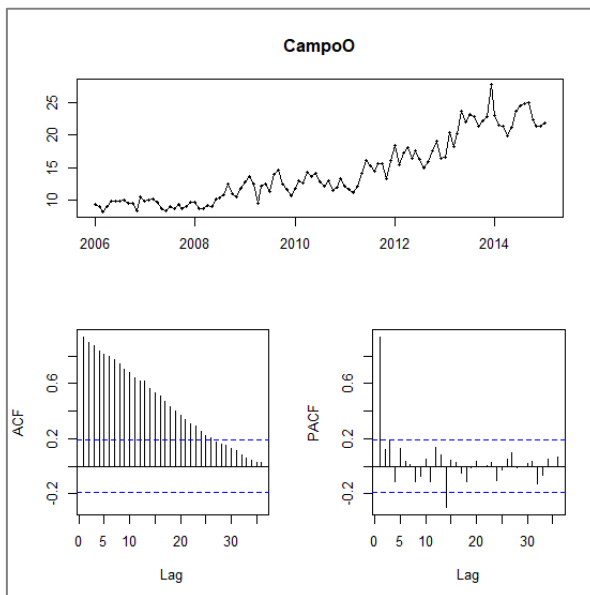

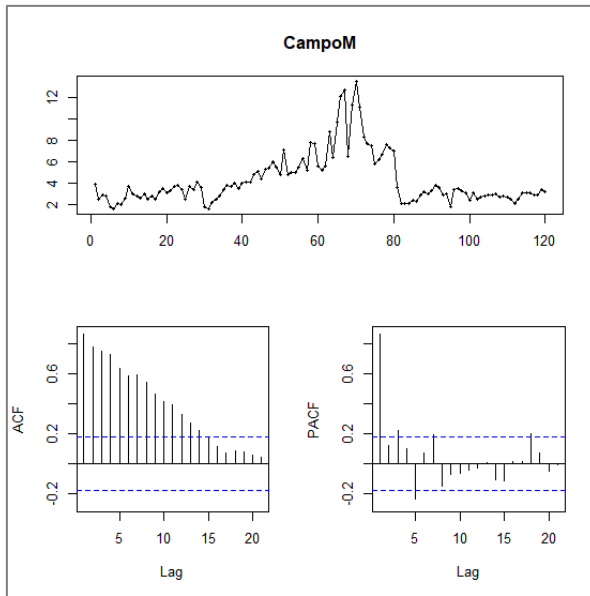
```
CampoRXbar <- dx.fit$residual  
qcc(CampoRXbar, type="xbar.one", center=0, std.dev=sd(residual), newdata=res,  
nsigmas=2.39)
```

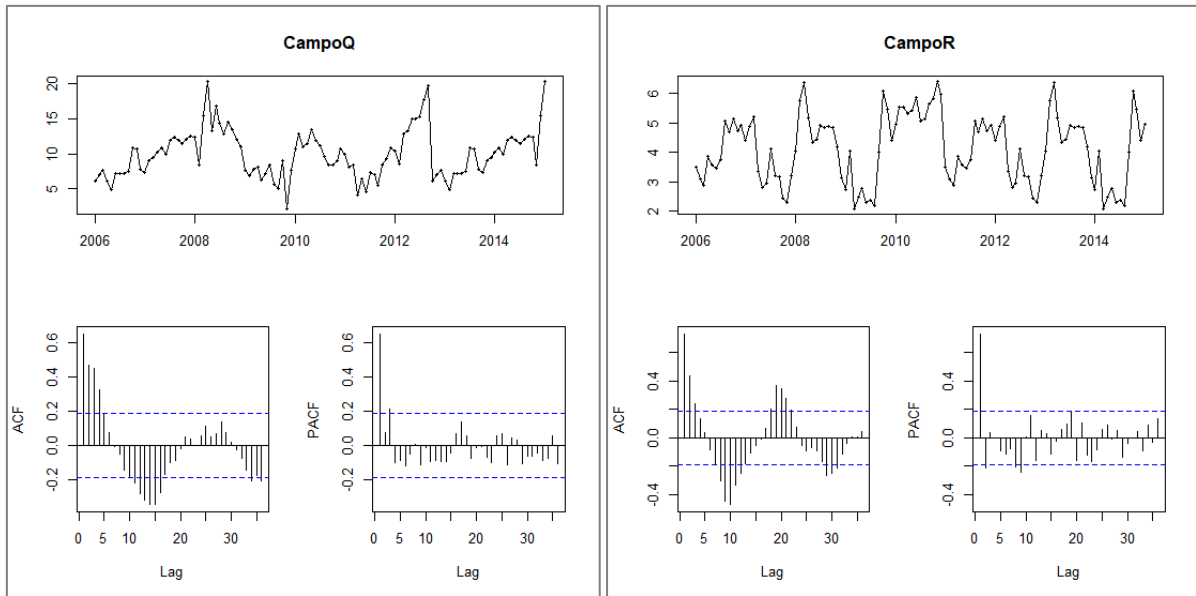
```
cusum(CampoRXbar, newdata=res, decision.interval = 4, std.dev=sd(residual), center = 0)
```

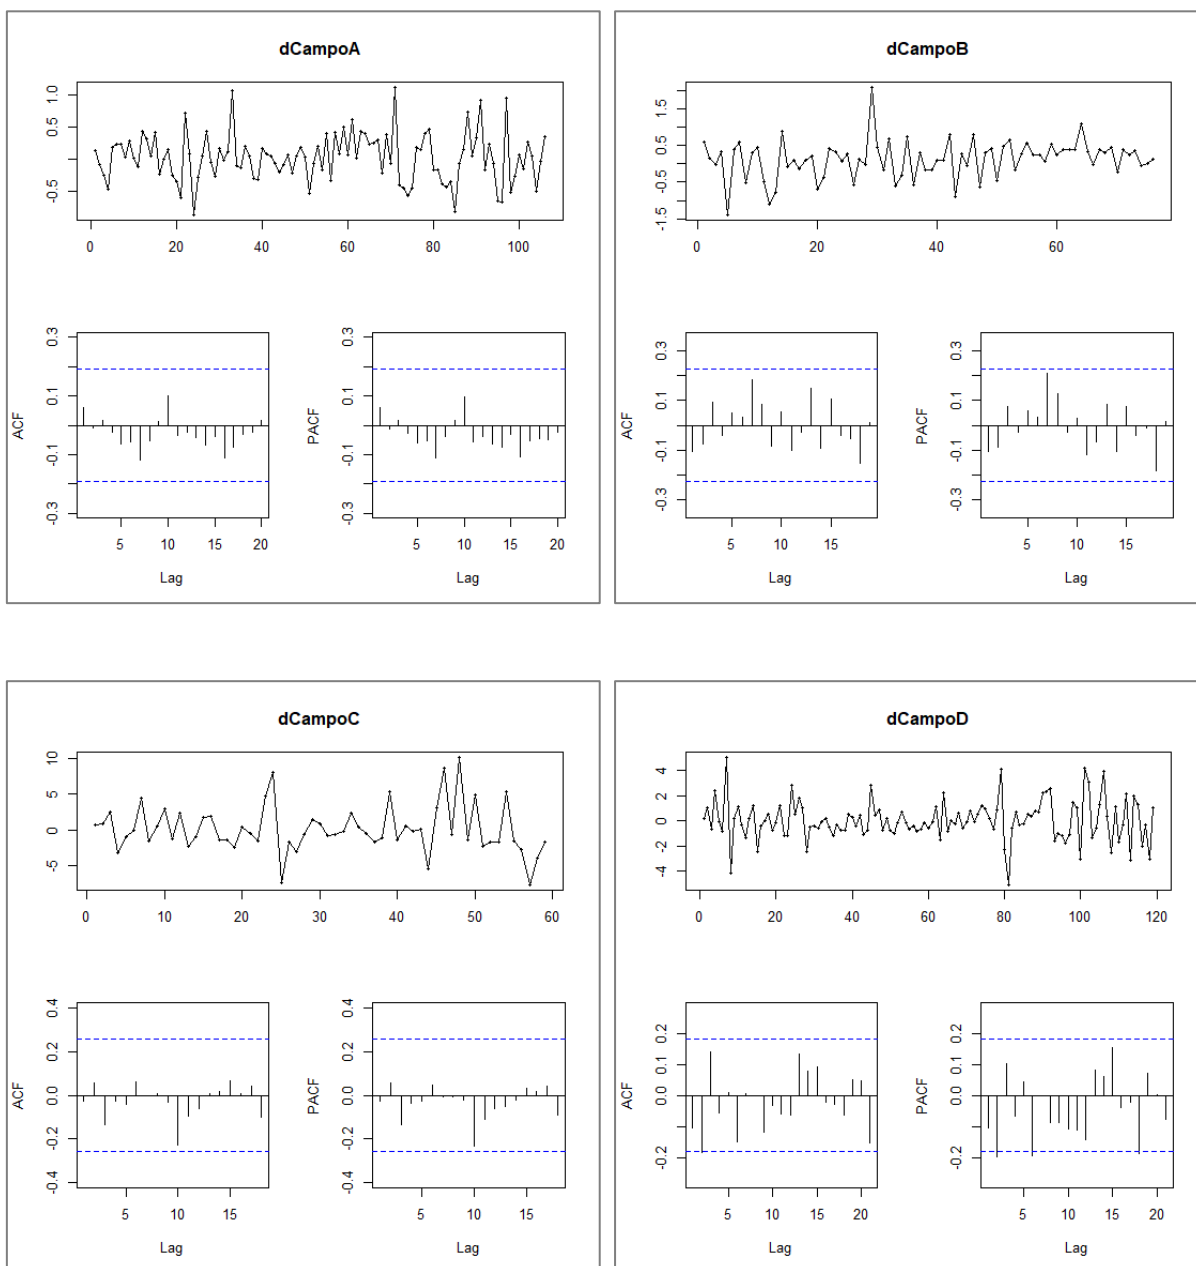
APÊNDICE B – ANÁLISES DAS SÉRIES TEMPORAIS DOS DADOS DE RAO


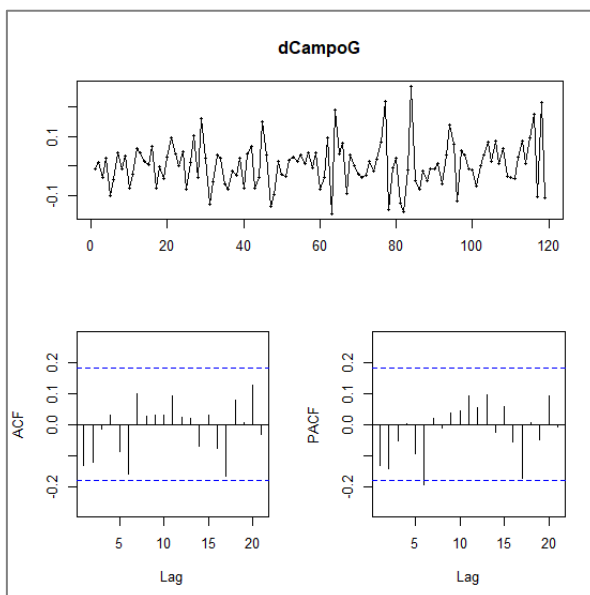





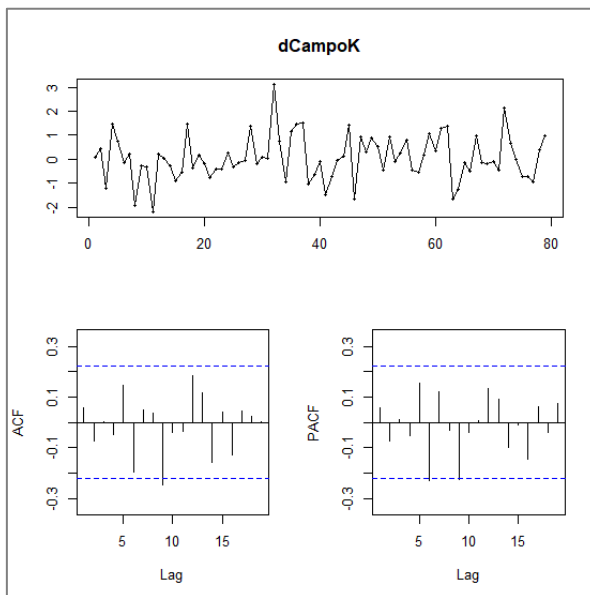





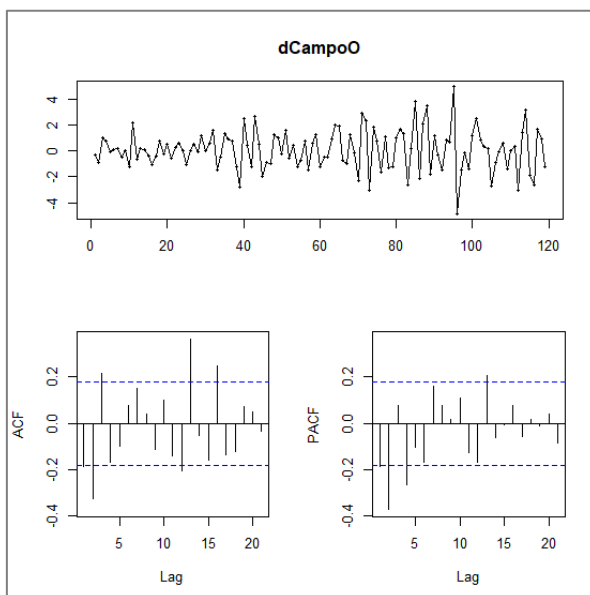








APÊNDICE C – ANÁLISES DAS PRIMEIRAS DIFERENÇAS DOS DADOS DE RAO









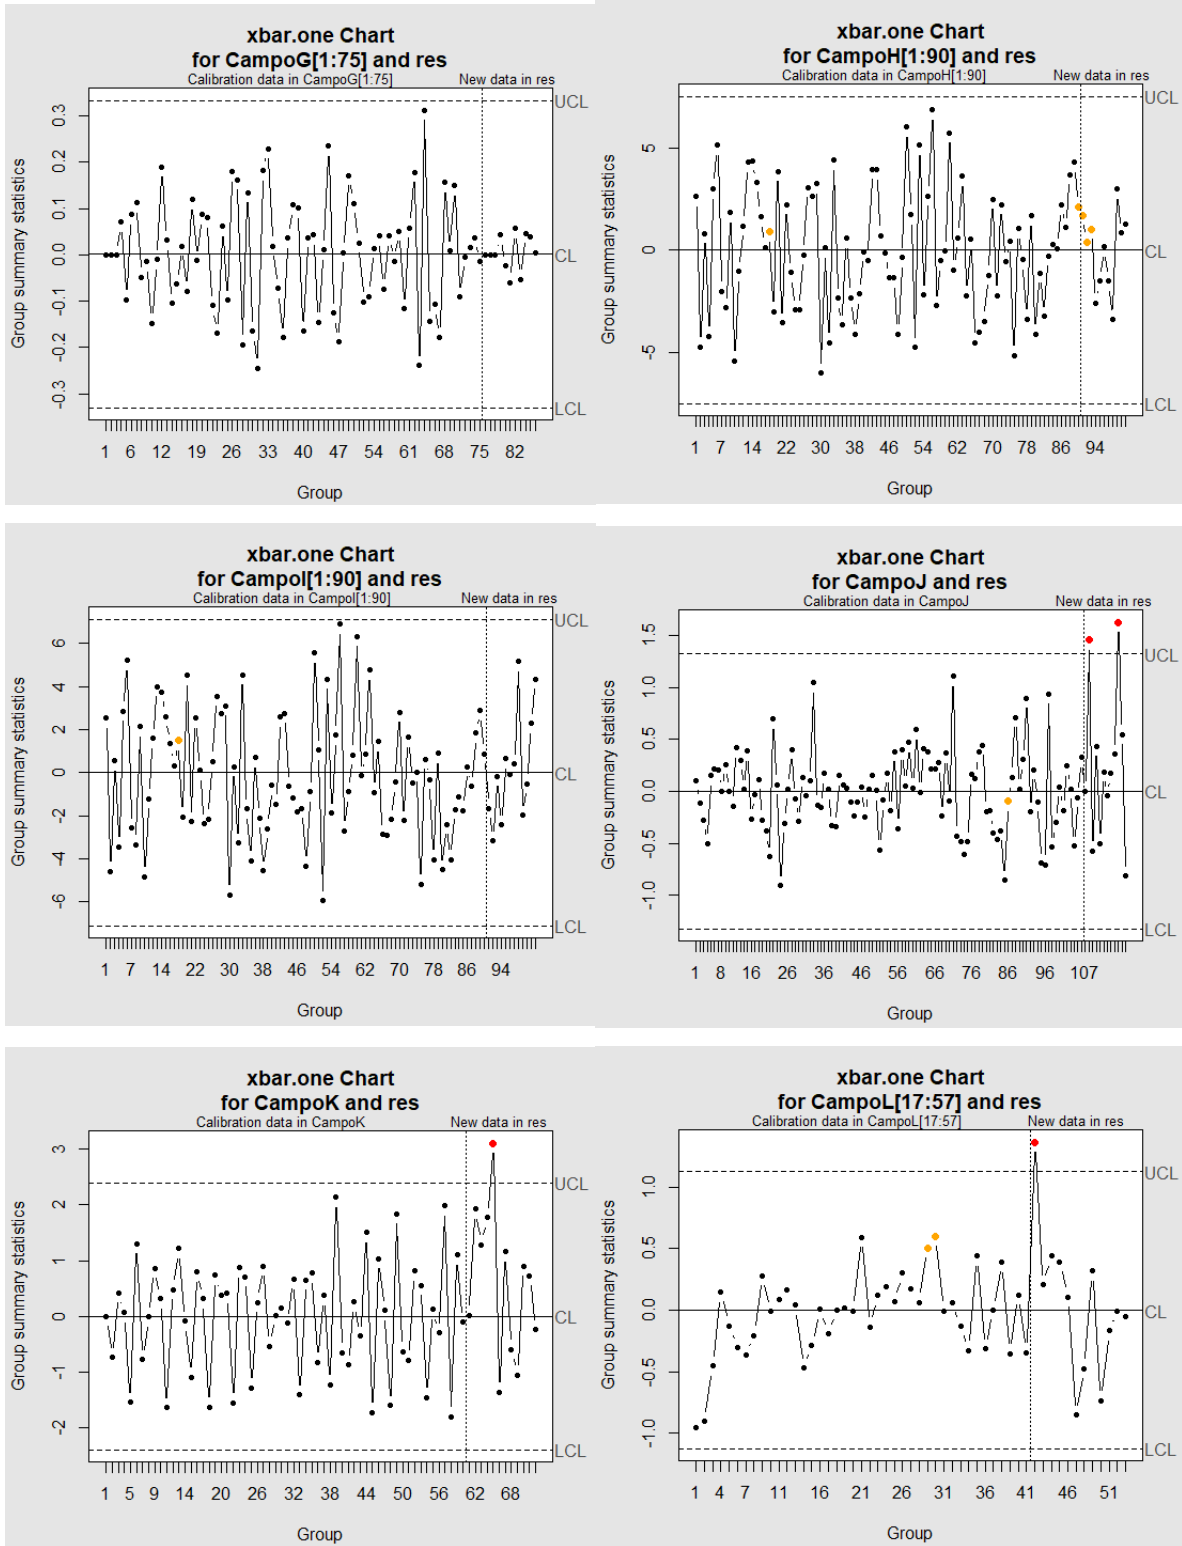









APÊNDICE D – GRÁFICOS DE CONTROLE SHEWHART







APÊNDICE E – GRÁFICOS DE CONTROLE CUSUM

